



João Pedro da Silva Varela

Licenciado em Ciências da Engenharia Eletrotécnica e de Computadores

Geração de conjuntos de treino a partir de imagem de satélite e de cartografia de ocupação de solo

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores

Orientador: André Damas Mora

Professor Auxiliar, Faculdade de Ciências e Tecnologia da
Universidade Nova de Lisboa

Presidente: Rodolfo Duarte Oliveira

Professor Auxiliar com Agregação, Faculdade de Ciências e
Tecnologia da Universidade Nova de Lisboa

Arguente: José Manuel Fonseca

Professor Associado com Agregação, Faculdade de Ciências e
Tecnologia da Universidade Nova de Lisboa



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Setembro, 2019

Geração de conjuntos de treino a partir de imagem de satélite e de cartografia de ocupação de solo

Copyright © João Pedro da Silva Varela, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

A todos os que contribuíram para a realização deste sonho.

Agradecimentos

Em primeiro lugar, gostava de agradecer ao professor André Damas Mora pela oportunidade da concretização desta dissertação, pela orientação prestada e pelos sábios conselhos dados durante a realização da mesma.

Agradeço também à Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa pelos conhecimentos que adquiri durante estes cinco anos de estudo. Ao grupo CA3 pela hospitalidade durante o período de desenvolvimento desta dissertação.

Agradeço à Fundação para a Ciência e Tecnologia pela bolsa de investigação inserida nos projetos IPSTERS (*IPSentinel Terrestrial Enhanced Recognition System - DSAIPA/AI/0100/2018*) e FUELMON (*Remote Fuel Break Monitoring for Forest Fire Protection - PTDC / CCI-COM / 30344 / 2017*).

Agradeço a todos meus familiares, especialmente aos meus pais, João Luís e Fernanda, que me deram a oportunidade de seguir este caminho, e que sempre me apoiaram.

Agradeço a todos os colegas que se tornaram grandes amigos e que me acompanharam durante estes cinco anos, por todos os momentos de convívio e pela disponibilidade de me ajudar sempre que precisei.

Um muito obrigado a todos os que contribuíram para a realização deste sonho.

O mapeamento da ocupação de solo é cada vez mais uma ferramenta fundamental em variadas áreas de investigação, como o ordenamento do território, a monitorização de áreas florestais ou na deteção de erosão do solo, sendo a rápida produção deste tipo de mapas cada vez mais necessária. O trabalho apresentado na presente dissertação vem combater a demorada atualização destes mapas através da criação de ferramentas que permitem a automatização da geração do conjunto de dados para posterior aplicação de técnicas de aprendizagem automática. Foi desenvolvida uma aplicação que permite ao utilizador selecionar polígonos que representem cada uma das Classes pretendidas, sendo depois gerado o conjunto de dados de acordo com os mesmos. Para a geração deste conjunto de dados são utilizadas imagens do nível 2A do *Sentinel-2*, sendo extraídos os atributos relativos a índices, transformações do espaço de cores e texturas. É também utilizada a Carta de Ocupação do Solo de Portugal Continental 2015, o último mapa produzido neste nível, que serve de referência. O conjunto de dados produzido consiste num grupo de imagens onde se encontra representada a área correspondente à imagem do *Sentinel-2* selecionada, cada imagem do conjunto de dados contém informações relativas a cada um dos atributos extraídos. Este conjunto de dados permite a criação de classificadores baseados numa abordagem ao nível do pixel. É ainda criado um ficheiro texto onde se encontram alguns dados estatísticos de cada um dos polígonos selecionados pelo utilizador, este ficheiro pode ser utilizado para aplicações de aprendizagem automática baseados na classificação de polígonos.

Palavras-chave: Deteção Remota; Extração de atributos; Criação de conjuntos de dados; Carta de Ocupação do Solo; Aprendizagem automática; *Sentinel-2*;

Abstract

Land cover mapping is rising in popularity as a research tool in a variety of research fields such as territorial planning, monitoring of forest areas or detecting soil erosion, and the rapid production of such maps is increasingly needed. The work presented in this dissertation fights the slow updating of these maps through the creation of tools that allow the automatization of dataset generation for later application in machine learning techniques. An application has been developed that allows the user to select polygons that represent each of the desired Classes, and then the dataset is generated accordingly. This dataset uses Sentinel-2 level 2A images, from it are extracted attributes such as indexes, color space transformations, and textures. The 2015 Continental Portuguese Land Cover Land Use map was employed as a reference as it is the last map of this level produced. The dataset produced consists of a group of images where the area corresponding to the selected Sentinel-2 image is represented, each image of the dataset contains information related to each of the extracted attributes. This dataset allows the creation of classifiers based on a pixel-level approach. Additionally, a text file is created which contains some statistical data for each of the user-drawn polygons, this file may be used for machine learning applications for a polygon-based classification.

Keywords: Remote Sensing; Feature Extraction; Dataset Generation; Land Cover Land Use map; Machine-learning; Sentinel-2

Índice

1	INTRODUÇÃO.....	1
1.1	MOTIVAÇÃO.....	1
1.2	CARTA DE OCUPAÇÃO DE SOLO.....	1
1.3	OBJETIVOS E CONTRIBUIÇÕES.....	3
1.4	ORGANIZAÇÃO DO DOCUMENTO.....	4
2	ENQUADRAMENTO TEÓRICO.....	7
2.1	DETEÇÃO REMOTA.....	7
2.1.1	<i>Radiação Eletromagnética.....</i>	<i>8</i>
2.1.2	<i>Resoluções.....</i>	<i>10</i>
2.2	<i>SENTINEL.....</i>	<i>11</i>
2.2.1	<i>Missões do Sentinel.....</i>	<i>11</i>
2.2.2	<i>Sentinel-2.....</i>	<i>13</i>
2.2.3	<i>IPSentinel.....</i>	<i>16</i>
2.3	SISTEMAS DE INFORMAÇÃO GEOGRÁFICA.....	17
2.3.1	<i>QGIS.....</i>	<i>18</i>
2.3.2	<i>ArcGIS.....</i>	<i>19</i>
2.3.3	<i>OSGeo4W.....</i>	<i>19</i>
3	ESTADO DE ARTE.....	21
3.1	PIXEL CONTRA OBJETO.....	21
3.2	SEGMENTAÇÃO.....	23
3.2.1	<i>Baseado em pontos.....</i>	<i>24</i>
3.2.2	<i>Baseado em contornos.....</i>	<i>24</i>
3.2.3	<i>Baseados em regiões.....</i>	<i>25</i>

3.2.4	<i>Bacias hidrográficas</i>	25
3.3	EXTRAÇÃO DE ATRIBUTOS	25
3.3.1	<i>Análise ao nível do Pixel</i>	26
3.3.2	<i>Análise baseada em Objetos</i>	33
3.3.3	<i>Análise baseada em Deep Learning</i>	33
3.3.4	<i>Seleção de atributos</i>	34
3.4	CLASSIFICAÇÃO.....	35
3.4.1	<i>Probabilidade máxima</i>	36
3.4.2	<i>Random Forest</i>	36
3.4.3	<i>Máquina de suporte de vetor</i>	36
3.4.4	<i>Redes Neurais</i>	37
3.4.5	<i>Lógica difusa</i>	37
3.4.6	<i>K-vizinhos mais próximos</i>	38
4	TRABALHO DESENVOLVIDO	39
4.1	DESCRIÇÃO DA APLICAÇÃO	39
4.2	ORGANIZAÇÃO DOS FICHEIROS DA APLICAÇÃO.....	40
4.3	COS_PORTUGAL	41
4.4	FICHEIROS UI.....	42
4.5	RESOURCES	43
4.6	ESTILO_COS	44
4.7	SETUP.....	45
4.8	LAUNCH	45
4.9	CREATE_WORKSPACE	46
4.9.1	<i>Criação do workspace</i>	46
4.9.2	<i>Dataset_Generation</i>	46
4.9.3	<i>my_shapes</i>	47
4.9.4	<i>Cos_workspace</i>	48

4.9.5	<i>Pasta dataset</i>	50
4.9.6	<i>Ficheiros Raster</i>	58
4.9.7	<i>Organização dos ficheiros gerados</i>	60
4.10	APP.....	60
4.10.1	<i>Load</i>	61
4.10.2	<i>Workspace e Raster</i>	61
4.10.3	<i>Canvas</i>	64
4.10.4	<i>Lista de polígonos</i>	65
4.10.5	<i>Legenda</i>	67
4.10.6	<i>Generate Dataset</i>	67
4.10.7	<i>Dataset final</i>	69
5	APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS	71
5.1	DADOS	71
5.2	EXTRAÇÃO DOS ATRIBUTOS	72
5.3	DATASET.....	76
5.3.1	<i>Avaliação dos atributos</i>	79
6	CONCLUSÕES E TRABALHO FUTURO	83
6.1	CONCLUSÕES.....	83
6.2	TRABALHO FUTURO	84
	REFERÊNCIAS	87
	ANEXOS	91

Lista de Figuras

FIGURA 1.1 - IMAGEM DA SUPERFÍCIE TERRESTRE E CORRESPONDENTES POLÍGONOS APRESENTADOS NA COS2015v1.0	2
FIGURA 2.1 - ASSINATURA ESPETRAL DA ÁGUA, DO SOLO E DA VEGETAÇÃO.....	8
FIGURA 2.2 - ESPETRO ELETROMAGNÉTICO COM AS POSSÍVEIS FREQUÊNCIAS DE RADIAÇÃO ELETROMAGNÉTICA	9
FIGURA 2.3 – REPRESENTAÇÃO DA FAMÍLIA DE SATÉLITES SENTINEL.....	12
FIGURA 2.4 – FREQUÊNCIA DE REVISITA DEVIDO A SOBREPOSIÇÃO DE IMAGENS DE ÓRBITAS.....	13
FIGURA 2.5 - LISTA DAS BANDAS CAPTADAS PELO SATÉLITE SENTINEL-2A.....	14
FIGURA 2.6 – EXEMPLO DE UTILIZAÇÃO DO <i>IPSENTINEL</i>	17
FIGURA 2.7 – EXEMPLO DE CAMADAS UTILIZADAS NUM PROGRAMA GIS	18
FIGURA 3.1 - COMPARAÇÃO DE CLASSIFICAÇÃO DA IMAGEM ORIGINAL NUMA ABORDAGEM AO NÍVEL DO PIXEL E AO OBJETO	23
FIGURA 3.2 - EXEMPLO DE IMAGEM SEGMENTADA, EXTRAÍDA ATRAVÉS DO <i>SOFTWARE ECOGNITION</i>	24
FIGURA 3.3 - EXEMPLO DO PROCESSO DE CRIAÇÃO DA GLCM PARA 8 NÍVEIS DE CINZENTO	30
FIGURA 3.4 - EXEMPLO DE IMAGEM COM BAIXO ASM E ALTO ASM	32
FIGURA 3.5 – CLASSIFICAÇÃO DE IMPORTÂNCIA DOS ATRIBUTOS PRECISÃO VS NÚMERO DE ATRIBUTOS	34
FIGURA 4.1 – DIAGRAMA EM ÁRVORE COM A DISTRIBUIÇÃO DOS FICHEIROS NA PASTA DA APLICAÇÃO..	40
FIGURA 4.2 – EXTRAÇÃO DOS DADOS DA COS PARA A SUB-REGIÃO OESTE UTILIZANDO O <i>PLUGIN “INSPIRE ATOM”</i>	42
FIGURA 4.3 – UTILIZAÇÃO DO PROGRAMA <i>QT DESIGNER</i> PARA DESENVOLVIMENTO DO FICHEIRO DATASET_GENERATION.UI.....	43
FIGURA 4.4 – CRIAÇÃO DO RECURSO COM OS ÍCONES DE CADA UMA DAS CLASSES.....	44
FIGURA 4.5 – CRIAÇÃO DO FICHEIRO “ESTILO_COS.QML” NO QGIS	45
FIGURA 4.6 – JANELA ‘DATASET_GENERATION.UI’	47
FIGURA 4.7 - IMAGEM AÉREA SOBREPOSTA COM OS POLÍGONOS DA COS QUE A INTERSETAM	49

FIGURA 4.8 - HISTOGRAMAS DA DISTRIBUIÇÃO DOS VALORES EXTRAÍDOS DO ATRIBUTO 'ENERGIA'	54
FIGURA 4.9 – REPRESENTAÇÃO DA EXPANSÃO DA IMAGEM.	55
FIGURA 4.10 – DIAGRAMA DO MÉTODO PARA O CÁLCULO DAS IMAGENS DA TEXTURA.....	57
FIGURA 4.11 - ESQUEMA EM ÁRVORE DA DISTRIBUIÇÃO DOS FICHEIROS DE UM NOVO WORKSPACE	60
FIGURA 4.12 - INTERFACE GRÁFICA DA APLICAÇÃO.....	61
FIGURA 4.13 - EXEMPLOS DE IMAGENS DOS VÁRIOS MODOS DE VISUALIZAÇÃO DA APLICAÇÃO.	63
FIGURA 4.14 - PROCESSO DE DESENHO DE UM NOVO POLÍGONO	65
FIGURA 4.15 - LISTA DOS POLÍGONOS DA COS	66
FIGURA 4.16 - LEGENDA DO MAPA COM RESPETIVO NÚMERO DE POLÍGONOS DESENHADOS E APROXIMAÇÃO DE QUANTIDADE DE PIXÉIS REPRESENTADOS.....	67
FIGURA 4.17 - EXEMPLO DE FICHEIRO 'DATASET.CSV'	69
FIGURA 4.18 - ESQUEMA EM ÁRVORE DOS FICHEIROS PRESENTES NA PASTA 'DATASET'	69
FIGURA 5.1 – MAPA COM ZONA DA IMAGEM DE <i>SENTINEL-2</i> DESCARREGADA PARA ESTE CASO DE ESTUDO.....	72
FIGURA 5.2 - REPRESENTAÇÃO DA IMAGEM "COR_NATURAL"	73
FIGURA 5.3 - REPRESENTAÇÃO DA IMAGEM "COS", REFERENTE À CARTA DE OCUPAÇÃO DE SOLO 2015.	73
FIGURA 5.4 - IMAGEM DO ATRIBUTO "NDVI"	74
FIGURA 5.5 - IMAGEM DO ATRIBUTO "NDWI"	75
FIGURA 5.6 - IMAGEM DO ATRIBUTO "B07".....	75
FIGURA 5.7 - IMAGEM DO ATRIBUTO "CONTRAST"	76
FIGURA 5.8 – HISTOGRAMAS DA DISTRIBUIÇÃO DOS VALORES DOS ATRIBUTOS PARA CADA UMA DAS CLASSES DOS ATRIBUTOS “ENERGIA”, “B07”, “NDWI” E “CORRELAÇÃO”	78
FIGURA 5.9 - VALORES DA CORRELAÇÃO PARA CADA UM DOS ATRIBUTOS EXTRAÍDOS.....	79
FIGURA 5.10 - VALORES DE CORRELAÇÃO ENTRE OS ATRIBUTOS EXTRAÍDOS.....	81
FIGURA 0.1 - IMAGENS DA ZONA DE CORTE DOS ATRIBUTOS EXTRAÍDOS.....	96
FIGURA 0.2 - HISTOGRAMAS DA DISTRIBUIÇÃO DOS VALORES DOS ATRIBUTOS PARA CADA UMA DAS CLASSES.	102

Lista de Tabelas

TABELA 1 - LISTA DE CLASS_ID E CORRESPONDENTE MEGACLASSE.....	48
TABELA 2 - LISTA DO MODOS DE VISUALIZAÇÃO COM AS RESPETIVAS BANDAS UTILIZADAS PARA AS COMPONENTES RGB.....	59
TABELA 3 - NÚMERO DE POLÍGONOS E PIXÉIS RETIRADOS DA CADA UMA DAS CLASSES.....	77

Lista de Acrónimos

AOT	<i>Aerosol Optical Thickness</i>
B	Azul
CAOP	Carta Administrativa Oficial de Portugal
CART	Classificação e regressão em árvore
CFS	Selecionador de atributos baseado na correlação
COS	Carta de Ocupação de Solo
DGT	Direção-Geral do Território
DHus	<i>Scientific Data Hub</i>
EC	Comissão Europeia
ESA	<i>European Space Agency</i>
EVI	<i>Enhanced Vegetation Index</i>
G	Verde
GDAL	<i>Geospatial Data Abstraction Library</i>
GIS	Sistema de informação geográfica
GLCM	<i>Gray Level Correlation Matrix</i>
GRASS	<i>Geographic Resources Analysis Support System</i>
FUELMON	<i>Remote Fuel Break Monitoring for Forest Fire Protection</i>
IHS	Intensidade-Tonalidade-Saturação
IPMA	Instituto Português do Mar e da Atmosfera

IPSentinel	Infraestrutura portuguesa para armazenamento e disponibilização de imagens <i>Sentinel</i>
IPSTERS	<i>IPSentinel Terrestrial Enhanced Recognition System</i>
MSI	Intrumento multi-espectral
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NIR	Infravermelho próximo
NUTS	Nomenclatura das unidades territoriais para fins de estatísticas
OSGeo	<i>Open Source Geospatial Foundation</i>
QGIS	<i>Quantum Geographic Information System</i>
R	Vermelho
RGB	Vermelho-Verde-Azul
SAGA	<i>System for Automated Geoscientific Analyses</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SWIR	Infravermelho de onda curta
TOA	Topo da atmosfera
USGS	<i>United States Geological Survey</i>
WMS	<i>Web Map Service</i>
WV	<i>Vapor de água</i>

1 Introdução

1.1 Motivação

O mapeamento através de imagens aéreas é, cada vez mais, um recurso fundamental utilizado em diversas áreas, desde monitorização de crescimento de cidades e de florestas, mapeamento dos fundos dos mares ou no planeamento do território. A criação deste tipo de mapeamento pode ser demorada, dependendo das ferramentas utilizadas, podendo demorar meses ou anos. Em certos casos como na deteção de áreas ardidas por incêndios ou na monitorização da altura de água nas barragens e lagos é necessária uma maior frequência na atualização destes mapeamentos. É, assim, importante a criação de ferramentas que permitam a automatização da geração deste tipo de mapas. Esta dissertação vem contribuir para esta automatização, sendo proposta uma ferramenta, a ser utilizada por competentes da área, que permite a criação automática de conjuntos de dados que poderão depois ser utilizados para a geração de modelos de inteligência artificial, diminuindo o tempo de produção de mapas de ocupação de solo e aumentando a sua frequência de atualização.

1.2 Carta de Ocupação de Solo

A carta de ocupação de solo (COS) é uma das cartografias onde é representado a ocupação e uso do solo em Portugal Continental e cuja entidade responsável é a Direção-Geral do Território (DGT). Até ao presente foram disponibilizadas quatro versões da COS: 1995, 2007, 2010 e 2015. Para o desenvolvimento desta dissertação foi uti-

lizada a versão mais recente (COS2015v1.0). Este tipo de cartografias tem um papel importante na tomada de decisões no ordenamento nacional do território, na monitorização ambiental, é também utilizada como ferramenta para planeamento político, económico e social.

A COS é uma cartografia de polígonos, onde cada um representa uma determinada ocupação do solo homogénea. Para que um polígono seja criado é necessário apresentar uma área superior à unidade mínima cartográfica definida (1 ha), uma distância entre linhas igual ou superior a 20m e uma percentagem da classe de uso de solo superior a 75% da área do polígono correspondente. Cada polígono é classificado apenas como uma das classes do nível mais detalhado listado em (Mário Caetano, 2018). A escala utilizada é de 1:25 000. Para a definição dos limites da COS 2015 foi utilizada a Carta Administrativa Oficial de Portugal (CAOP) onde é estabelecida a fronteira com Espanha. A fronteira marítima, por sua vez, foi definida por fotointerpretação. Para verificar a qualidade dos resultados foram utilizadas diversas bases de dados auxiliares, a respetiva lista encontra-se em (Mário Caetano, 2018). A COS 2015 tem uma exatidão posicional igual ou inferior a 5,5m com níveis de exatidão de classes de 96% (Nível 1), 90% (Nível 2), 88% (Nível 3), 88% (Nível 4) e 83% (Nível 5).



Figura 1.1 - Imagem da superfície terrestre (esquerda) e correspondentes polígonos apresentados na COS2015v1.0 (direita). Retirado de <http://snig.dgterritorio.pt/>.

As imagens aéreas utilizadas como referência para a produção da COS 2015 foram recolhidas nos meses de abril, maio e junho de 2015, a 6500 metros de altura. Apresentam assim uma resolução espacial de 0,5x0,5m no terreno. Foram recolhidos dados referentes às bandas vermelho, verde, azul e infravermelho próximo, cada uma com uma resolução radiométrica de 8 bits (256 valores). Estas imagens são ortoretificadas e dão origem à cartografia COS no formato *ESRI shapefile*. Na versão 2015 cada

polígono contém informação, nomeadamente a sua área (ha), um código da classe de uso do solo no nível 5, descrição da Classe e da Megaclasse e o identificador numérico único do polígono (Mário Caetano, 2018). Esta carta encontra-se disponível através de um serviço WMS (*Web Map Service*), que é uma interface para pedidos de imagens registadas em várias bases de dados geo-espaciais.

As Classes contidas na COS encontram-se divididas em 5 níveis hierárquicos de complexidade crescente:

- 1º nível – 5 classes (Territórios artificializados, áreas agrícolas e agro-florestais, florestas e meios naturais e semi-naturais, zonas húmidas e corpos de água);
- 2º nível – 14 classes;
- 3º nível – 32 classes;
- 4º nível – 34 classes;
- 5º nível – 48 classes;

A listagem dos nomes das classes em cada um dos níveis bem como a sua descrição detalhada encontra-se disponível em (Mário Caetano, 2018). Durante o desenvolvimento desta dissertação apenas foram consideradas as Megaclasses definidas para cada um dos polígonos pela COS 2015, esta é um nível de detalhe um pouco superior ao primeiro nível apresentado anteriormente. A Megaclasse contém 9 classes distintas: Territórios Artificializados, Agricultura, Pastagens, Sistemas Agro-Florestais, Floresta, Matos, Espaços descobertos ou com vegetação esparsa, Zonas húmidas e Corpos de Água.

1.3 Objetivos e Contribuições

Esta dissertação vem contribuir para a automatização do processo de criação de mapas de ocupação do território como a COS, permitindo diminuir significativamente o tempo necessário para a criação ou atualização dos mesmos. Esta automatização será possível devido à utilização de técnicas de aprendizagem automática, doravante denominada *machine learning*, onde será construído um classificador que através das imagens aéreas recolhidas por satélite será capaz de atribuir, com um certo nível de incerteza, o tipo de utilização de solo a cada um dos pixels dessa mesma imagem. Estes modelos serão gerados através de técnicas de *machine learning* com aprendizagem supervisionada, o que implica existência de um conjunto de dados previamente classificados. Este conjunto de dados designa-se *dataset*. O principal objetivo deste trabalho é

o desenvolvimento de uma ferramenta que automatize ao máximo o processo de criação deste *dataset*. A ferramenta foi produzida utilizando a linguagem de programação *Python*.

A ferramenta está desenhada para ser utilizada por um utilizador perito em mapeamento de território. Através de imagens de satélite, bem como da informação referente à COS, é possível ao utilizador escolher quais as zonas de interesse para cada uma das Classes de estudo, na região contida nessa respetiva imagem de satélite. Será depois gerado de forma automática o *dataset* referente a essa mesma imagem, extraindo atributos da imagem como bandas, índices de vegetação ou texturas.

A criação deste tipo de ferramentas será cada vez mais uma necessidade graças à evolução da tecnologia e ao aumento significativo da quantidade de dados recolhidos pelos satélites. Na altura da escrita desta dissertação não foram encontradas aplicações desenhadas com o mesmo objetivo da desenvolvida na mesma. No entanto, existem já algumas técnicas criadas para a extração de atributos da imagem inseridas em Sistemas de informação geográfica, como o QGIS.

A presente dissertação faz, ainda, parte dos projetos, IPSTERS (*IP Sentinel Terrestrial Enhanced Recognition System - DSAIPA/AI/0100/2018*), cujo principal objetivo é a exploração de aplicações da inteligência artificial para produção de mapas de ocupação de solo com a mínima intervenção humana possível e FUELMON (*Remote Fuel Break Monitoring for Forest Fire Protection - PTDC / CCI-COM / 30344 / 2017*) que visa monitorização do estado de conservação de faixas de gestão de combustível.

1.4 Organização do Documento

A presente dissertação está dividida em seis capítulos. O primeiro capítulo contém uma descrição da motivação e objetivos do trabalho bem como uma explicação da COS 2015. O enquadramento teórico encontra-se no segundo capítulo, onde são apresentados os conceitos mais importantes para a melhor compreensão desta dissertação. Começa-se pela descrição do conceito de detecção remota, depois são apresentadas as missões Sentinel e por fim os sistemas de informação geográfica. No terceiro capítulo encontra-se o estado da arte, onde são expostos os métodos utilizados em projetos na área da detecção remota, na lista de métodos encontram-se a segmentação, a extração de atributos

tos e a classificação. No quarto capítulo está descrito detalhadamente o trabalho desenvolvido. A apresentação e discussão de resultados contém um exemplo de um conjunto para treino gerado, e no último capítulo encontram-se as conclusões da dissertação e quais os possíveis pontos a serem melhorados no futuro.

2 Enquadramento Teórico

Neste capítulo encontra-se um enquadramento teórico dos assuntos necessários para uma correta interpretação desta dissertação. É dado a conhecer o conceito de deteção remota, bem como um pouco da sua história, depois são introduzidos os satélites *Sentinel*, um conjunto de missões que vem melhorar a qualidade das imagens de observação da terra, e por fim é descrito o que são os sistemas de informação geográfica.

2.1 Deteção Remota

Deteção remota é um conceito criado na década de 60 que consiste na medição de um determinado objeto sem interação ou contato direto com o mesmo. Para medições geográficas são utilizados vários tipos de sensores, fixos a um veículo aéreo, como câmaras. Numa fase inicial da tecnologia eram utilizados balões e até pombos para retirar imagens aéreas da superfície terrestre. Com o lançamento do *Sputnik*, primeiro satélite em órbita na Terra, em 1957, tornou-se possível a recolha de imagens da superfície da terra através de um satélite em órbita. Os primeiros satélites lançados para o espaço com este objetivo datam do final da década de 60, e apenas conseguiam captar imagens a preto e branco.

A evolução da deteção remota na década de 60 levou ao lançamento do *Landsat I*, em 1972. Este foi o primeiro satélite em órbita do planeta com o objetivo exclusivo de monitorização e recolha de informações relativas à superfície da Terra. Na década de 80 foram introduzidos novos tipos de sensores, nomeadamente o CZCS (para deteção da cor dos oceanos), o HCM (sensor térmico) e o AVHRR (radiômetro de 4 bandas

distintas). Estes tipos de sensores ainda são utilizados na atualidade, substituindo em muitos casos a imagem fotográfica.

Hoje em dia são utilizados aviões, *drones* e satélites como meio para captar as imagens da detecção remota. Projetos como o *Landsat* (USGS/NASA) e o *Sentinel* (ESA) disponibilizam dados da superfície terrestre de todo o planeta, permitindo um grande número de investigadores na área, e consequente grande desenvolvimento das tecnologias de visualização, correção e classificação da superfície do nosso planeta.

2.1.1 Radiação Eletromagnética

Todos os objetos, a uma temperatura superior ao zero absoluto, emitem energia eletromagnética, que é captada pelos sensores utilizados na detecção remota. A energia eletromagnética emitida pelo Sol é refletida por um determinado objeto que se encontra na superfície da Terra, que é depois transmitida até ao sensor fixo ao nosso veículo aéreo. A leitura do sensor depende diretamente da quantidade de energia refletida pelo objeto na superfície da Terra. Aos valores de energia emitidos por um determinado objeto dá-se o nome de resposta padrão espectral, também conhecida como assinatura espectral. Na figura 2.1 é possível visualizar as assinaturas espectrais da água (azul), do solo (castanho) e da vegetação verde (verde). Facilmente se verifica que as assinaturas são bastante diferentes, este tipo de análise permite distinguir e corretamente classificar os vários tipos de superfícies.




Figura 2.1 - Assinatura espectral da água (azul), do solo (castanho) e da vegetação (verde). Retirado de <https://grindgis.com/remote-sensing/vegetation-spectral-signature-heat-sheet>

A Terra reflete cerca de um terço da energia eletromagnética proveniente do Sol, a restante é perdida através da reflexão da atmosfera ou absorvida pelo planeta, o que adiciona um nível acrescido de perturbações a todo o sistema. Para tentar corrigir este tipo de problemas, foram desenvolvidos índices que utilizam os valores recolhidos pelos sensores e/ou alguns parâmetros ajustáveis, alguns apresentados no subcapítulo 3.3.1.

O espectro eletromagnético representado na figura 2.2, descreve os vários comprimentos de ondas eletromagnéticas existentes. A cada grupo de comprimento de onda é dado o nome de banda, ultravioleta, infravermelho ou micro-ondas são exemplos de bandas. É possível verificar que existe uma zona de luz visível, esta representa os comprimentos de onda visíveis ao olho humano. No entanto, para a correta classificação dos objetos presentes na superfície da Terra, são também utilizados outros tipos de onda, como seja o infravermelho próximo (NIR).




Figura 2.2 - Espectro eletromagnético com as possíveis frequências de radiação eletromagnética. Retirado de <https://blogs.ubc.ca/communicatingscience2014w112/tag/electromagnetic-spectrum/>

Apesar do espectro eletromagnético ser contínuo, ou seja, existe a possibilidade de ler valores de radiação em qualquer das frequências pretendidas, nem sempre são utilizados todos os comprimentos de onda. A utilização de uma quantidade reduzida de bandas diminui a quantidade de atributos a serem utilizados pelo modelo classificador diminuindo a sua complexidade. Quando é analisado um número reduzido de bandas (geralmente de 3 a 10 bandas) o processo é denominado de análise multiespectral, enquanto que ao utilizar centenas de milhares de bandas estamos a executar uma análise híper espectral.

2.1.2 Resoluções

A boa qualidade dos dados captados pelo sensor é um fator chave para a criação de um sistema automático de classificação, e a resolução do sensor pode ser determinante neste papel. Existem vários tipos de resolução:

- A resolução espectral é dada pelo intervalo de comprimento de onda que o sensor pode variar ao amostrar um determinado comprimento de onda, com valores desta resolução muito baixos, existe a possibilidade de sobreposição de bandas.
- A resolução espacial consiste no tamanho real correspondente a um pixel na imagem recolhida, imagens com maior resolução espacial apresentam um nível de detalhe superior, permitindo a deteção de objetos mais pequenos.
- A resolução radiométrica é a capacidade que o sensor tem de, na mesma banda, distinguir valores de energia radiométrica distintos. Sensores com maior resolução radiométrica têm uma gama de valores recolhidos superior e com maior precisão, é comum ter sensores com 8 ou 10 bits de resolução radiométrica, correspondendo a 256 ou 1024 valores distintos possíveis de nível de radiação medidos.
- A resolução temporal é a capacidade que o sensor possui de frequência de recolha de dados no mesmo local. Esta resolução é muito importante para estudos de monitorização e deteção de alterações na superfície da Terra, como incêndios, cheias ou desflorestação.

2.2 *Sentinel*

O *Sentinel* é um conjunto de missões que estão a ser realizadas pela *European Space Agency* (ESA) e está inserido no programa Copernicus. O programa Copernicus é liderado pelo *European Commission* (EC) em parceria com a ESA, sendo esta última a principal responsável pelo desenvolvimento e lançamento dos satélites *Sentinel*. É um programa ambicioso, que tem como objetivo facilitar o acesso a este tipo de informação, esta pode ser utilizada para gestão ambiental, evitar mudanças climáticas ou até garantir a segurança da população.

As missões *Sentinel* vêm substituir os sistemas de observação da Terra mais antigos que já se encontram na fase final da duração de funcionamento para o qual foram desenvolvidos. Cada uma das missões tem um objetivo distinto e bem definido, entre eles observação da atmosfera, oceano e superfície terrestre. Para cumprir os objetivos das missões *Sentinel* é lançado um par de satélites para cada uma das missões, desta forma é possível aumentar a informação recolhida, tornando o sistema mais robusto e completo.

2.2.1 Missões do *Sentinel*

Como referido anteriormente existem várias missões do *Sentinel* com objetivos distintos, a lista de missões e correspondentes objetivos é apresentada de seguida.

- ***Sentinel-1*** – Monitorização de superfície terrestre e oceanos, estes satélites estão em funcionamento, ininterruptamente durante o dia e a noite. Captam imagem de radar o que os torna robustos no que toca a condições meteorológicas.
- ***Sentinel-2*** – Monitorização da superfície terrestre através de imagens multiespectrais de alta resolução. As imagens recolhidas por este tipo de missões é muito utilizada para identificação do tipo de terreno (vegetação, solo, água, etc.).
- ***Sentinel-3*** – Medição topográfica da superfície do mar, medições da temperatura da superfície terrestre e oceanos, e deteção da cor dos mesmos. Esta missão vem recolher informação que nos é útil para previsões de correntes marítimas e monitorização de alterações ambientais.

- **Sentinel-5P** – Medições atmosféricas, relativas a qualidade do ar, alterações climáticas, camada do ozono e radiação ultra-violeta. Foi desenvolvido para preencher a falta de informação deste tipo a partir da paragem de funcionamento do satélite Envisat da *National Aeronautics and Space Administration* (NASA).
- **Sentinel-4/5** – Este grupo de satélites ainda não foram lançados, mas terá como objetivo a monitorização da atmosfera terrestre.
- **Sentinel 6** – Missão ainda em desenvolvimento, que tem como objetivo a monitorização a altura do nível da água do mar.




Figura 2.3 – Representação da família de satélites SENTINEL

(http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4)

2.2.2 *Sentinel-2*

As imagens utilizadas durante este trabalho foram captadas através da missão *Sentinel-2*, uma vez que o seu objetivo é a identificação do tipo de solo da superfície terrestre. Esta missão é constituída por dois satélites que se encontram em órbita desfasados de 180°, cada um deles com uma resolução temporal de 10 dias (tempo que o satélite demora a visitar o mesmo local, nas mesmas condições de perspetiva), o que dá origem a uma resolução do sistema de 5 dias. As latitudes máximas de recolha de imagem destes satélites são de 56° para Sul e 84° para Norte. Devido à sobreposição de imagens com latitudes semelhantes, são recolhidas imagens de determinadas áreas da superfície terrestre com maior frequência, como representados na figura 2.4.

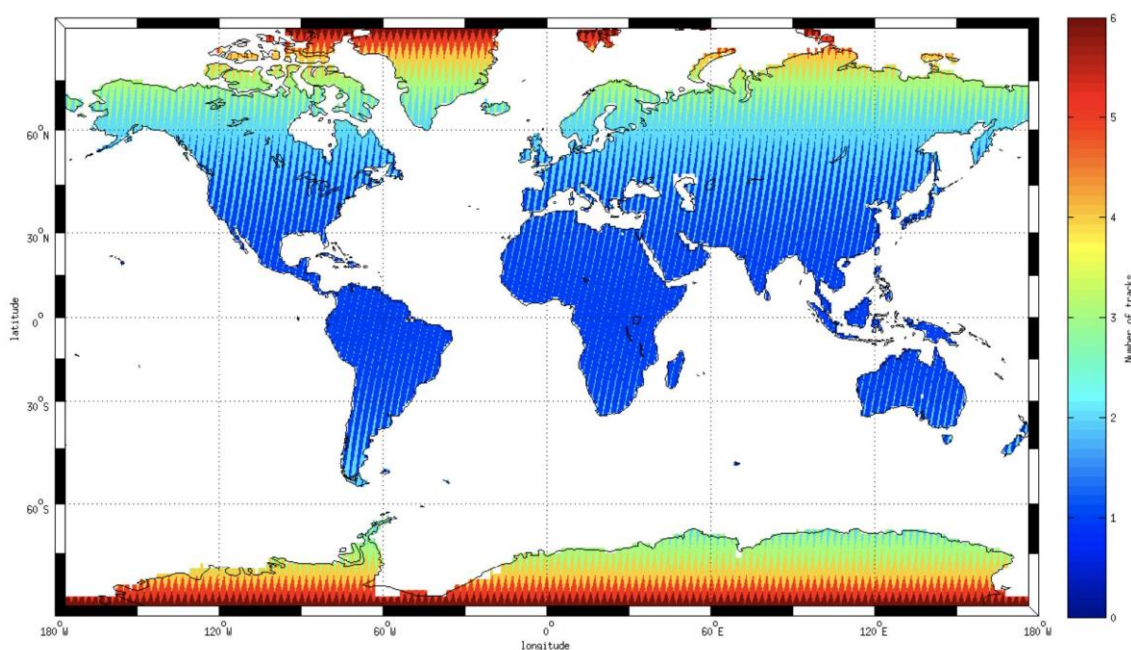


Figura 2.4 – Frequência de revisita devido a sobreposição de imagens de órbitas adjacentes (<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/revisit-coverage>)

Os satélites orbitam a Terra a uma altitude de 786km o que permite ter uma abertura da lente do sensor correspondente a 290km na superfície. O satélite está preparado para operar durante 7,25 anos, tendo sido munido de bateria para cerca de 12 anos, com peso aproximado de 1,2 toneladas. Para recolha de imagem está instalado no satélite um instrumento multi-espectral (MSI), que vai recolhendo imagens ao longo do

varrimento da sua órbita, este sensor ótico permite recolher informação de 13 bandas espectrais, com resolução espacial desde os 10m até aos 60m.




Figura 2.5 - Lista das bandas captadas pelo satélite Sentinel-2A, com correspondente comprimento de onda médio, largura de banda e resolução. Retirado de (Immitzer, Vuolo, & Atzberger, 2016)

2.2.2.1 Áreas de aplicação

Tomando partido da assinatura espectral de cada tipo de solo, podemos identificar várias áreas onde poderão ser aplicadas as bandas recolhidas pelo Sentinel-2 ("GisGeography," 2018).

- **Aerosol** – Consegue penetrar a água, pelo que é utilizada para monitorização da vegetação aquática e análise da população de baleias. A banda é também utilizada para deteção de nuvens e fumos.
- **Azul** – Esta banda tem capacidade de penetrar na água, é útil para monitorização de áreas costeiras, recifes, turbulência da água, sedimentação. Deteção de plumas de fumo, e diferenciação entre nuvens, neve ou rochas.

- **Verde** – Valores elevados na banda verde podem significar presença de vegetação. É também utilizada para detecção de cianobactérias.
- **Vermelho** – Identificação do tipo de solo. Utilizada em índices de vegetação como o NDVI devido à grande absorção desta banda por parte das plantas. Distinção de ambientes naturais e artificiais.
- **Borda Vermelha** – Detecção de zonas com presença de clorofila, sendo um bom qualificador do nível de vitalidade das plantas, bem como monitorização de campos agrícolas.
- **Infravermelho Próximo (NIR)** – Muito utilizada para identificar a presença de vegetação saudável.
- **Cirro** – Esta banda é absorvida pela atmosfera, o que torna possível a identificação de nuvens.
- **Infravermelho de onda curta (SWIR)** – Distinção de terrenos secos e húmidos. Esta banda consegue penetrar fumos, sendo utilizada como auxílio no combate a incêndios.

2.2.2.2 Tipos de produtos

Os sensores instalados nos satélites *Sentinel* recolhem informação relativa à luz refletida na superfície terrestre, porém, esta informação não é diretamente disponibilizada para os utilizadores, sendo necessária um processamento prévio da imagem melhorando a sua qualidade. As diversas etapas deste processamento dão origem a vários tipos de produto, sendo apenas os produtos do tipo 1C e 2A partilhados abertamente.

- **Nível-0** – Informação comprimida, recolhida diretamente pelo sensor, sem qualquer tipo de processamento. Este nível contém uma estrutura onde se encontra a descrição da imagem, a imagem comprimida e conjuntos de dados adicionais que serão úteis para criação de produtos de nível superior, como altitudes e temperaturas.
- **Nível-1A** – Para obtenção de produtos deste tipo a imagem do nível anterior é descomprimida e é-lhe atribuída um modelo geométrico, o que permite a localização de cada um dos pixéis da imagem.
- **Nível-1B** – Os produtos deste tipo vêm trazer correções radiométricas para as imagens do topo da atmosfera (TOA). É ainda definido um novo modelo geométrico que será depois utilizado para geração das imagens do Nível-1C.

- **Nível-1C** – Estas imagens são mosaicos de 100x100km², com um tamanho de aproximadamente 600MB cada, correspondem às projeções no sistema UTM/WGS84, que divide a superfície terrestre em 60 zonas. Este produto resulta da utilização de um modelo de elevação digital que projeta a imagem numa geometria cartográfica. São posteriormente reamostradas com o uso da distância de amostra no solo que consiste na distância entre dois pixéis consecutivos medidos na distância no solo. Este produto encontra-se disponível para os utilizadores.
- **Nível-2A** – Este produto é uma imagem da camada a baixo da atmosfera, ou seja, o seu principal objetivo é retratar a superfície terrestre descartando tudo o que se trata de perturbações atmosféricas, é o tipo de imagem utilizado nesta dissertação. Para produção de tipo de produtos é realizada uma correção atmosférica ao produto do nível anterior. São adicionados novos tipos de imagem auxiliar: *Aerosol Optical Thickness (AOT)*, vapor da água (*WV*) e um mapa classificado, juntamente com um indicador de qualidade de imagem para efeitos de níveis de nuvens e neve presentes na imagem. Neste produto a banda 10 é omitida uma vez que não apresenta informações relativas à superfície terrestre. Estas imagens são também mosaicos de 100x100km², sendo que cada uma tem um tamanho de cerca de 800MB, com uma resolução radiométrica de 10000 níveis de intensidade.

2.2.3 *IPSentinel*

As imagens disponibilizadas pelo projeto *Copernicus* podem ser encontradas na página *web* do *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/>). Em Portugal foi criado o portal *IPSentinel* – “Infraestrutura portuguesa para armazenamento e disponibilização de imagens dos satélites *Sentinel*”, pela DGT em parceria com o Instituto Português do Mar e Atmosfera (IPMA). O objetivo deste portal é disponibilizar abertamente o acesso às imagens do território português obtidas pelas missões *Sentinel-1*, *Sentinel-2* e *Sentinel-3*, fazendo parte da ação na política de participação de Portugal no *Copernicus*.

O *IPSentinel* tem por base o *software* de código aberto da ESA, o *Scientific Data Hub (DHus)*, que permite ao utilizador descarregar a informação pretendida. O utilizador selecionará uma área de interesse, e será disponibilizada uma lista de produtos que correspondem a essa área de procura, sendo ainda possível filtrar os resultados, por exemplo, por missão, nível do produto, percentagem de nuvens presente na ima-

gem ou data de recolha da imagem. Na figura 2.6 encontra-se um exemplo de utilização deste portal.

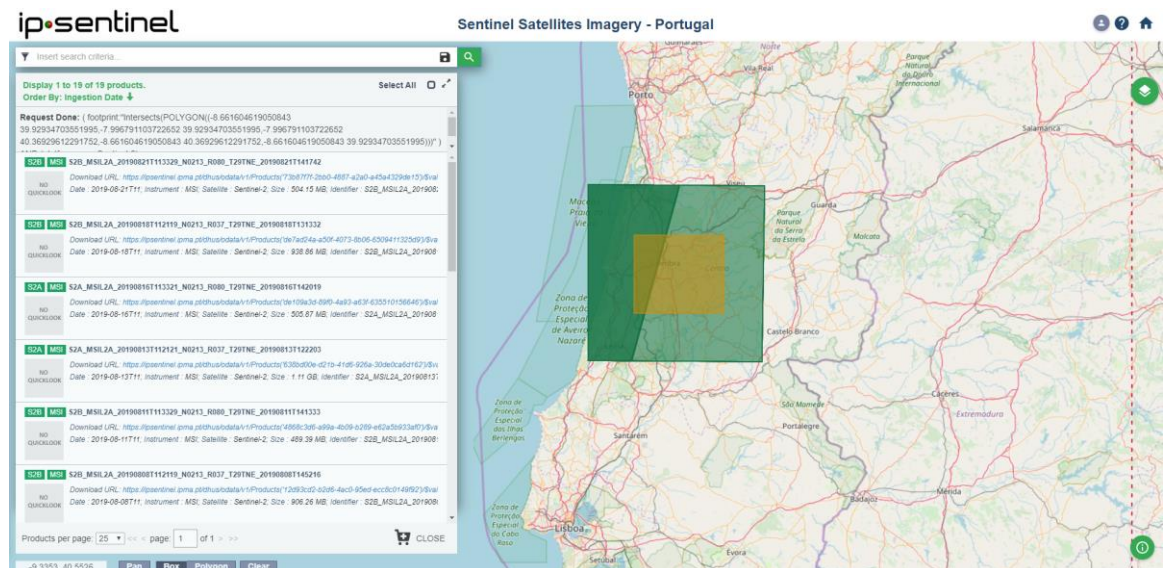


Figura 2.6 – Exemplo de utilização do *IP Sentinel* (à esquerda – lista de produtos que intersejam a área de interesse; à direita – mapa onde é marcada a área de interesse [amarelo] e é apresentada a área correspondente aos resultados obtidos na pesquisa [verde]). Retirada de <https://ipsentinel.ipma.pt/dhus/#/home>

2.3 Sistemas de informação geográfica

Sistemas de informação geográfica (GIS) são sistemas desenhados para manusear dados geográficos, desde a sua captura e manipulação até à sua análise e representação gráfica. Estes tipos de programas são cada vez mais utilizados por empresas para resolução de problemas em variadas áreas. Aplicações GIS são programas especialmente desenvolvidos para armazenamento, edição, processamento e representação de informações geográficas. Estas aplicações devem ser capazes de tratar dados espaciais, bem como dados qualitativos.

Os dados espaciais representam informações diretas da superfície terrestre, estradas, rios, edifícios ou terrenos agrícolas são exemplos deste tipo de dados. Por outro lado, dados qualitativos são dados que geralmente são obtidos por outros meios que não as imagens aéreas, como inquéritos à população, contagens, ou outro tipo de estudos. A ligação entre estes dois tipos de dados pode dar origem a mapas de mais fácil

interpretação. Na 2.7 é possível ver um exemplo da utilização de vários tipos de camadas com origens distintas, que sobrepostas possibilitam outro tipo de observações.




Figura 2.7 – Exemplo de camadas utilizadas num programa GIS. Retirada de <https://2012books.lardbucket.org/books/geographic-information-system-basics/s05-introduction.html>

2.3.1 QGIS

O Quantum GIS (QGIS) é um programa GIS que foi começado a ser desenvolvido em 2002 por Gary Sherman, atualmente faz parte do projeto *Open Source Geospatial Foundation (OSGeo)*. O QGIS é um projeto de código aberto está a ser desenvolvido por um conjunto de voluntários.

O QGIS oferece variadas funcionalidades através não só das suas funções, como também através de *plugins*, que são desenvolvidos pela comunidade e disponibilizados abertamente no QGIS. Fazendo uma breve descrição das suas funcionalidades, o QGIS permite a visualização de dados (vetores ou *rasters*; vetores são imagens que podem ser descritas através de um conjunto de polígonos, e *rasters* são imagens constituídas por grandes quantidades de pequenos quadrados chamados pixéis), exploração e composição de mapas (criação de mapas facilitada com recurso à área de desenho e a uma interface gráfica de fácil aprendizagem); criar, editar e exportar vários dados em variados formatos (GPX, tiff, shp, etc.); análise de dados (através de análise espacial, utilizando ferramentas como o *Geospatial Data Abstraction Library (GDAL)*, *System for Automated Geoscientific Analyses (SAGA)* ou *Geographic Resources Analysis Su-*

pport System (GRASS), que estão contidas no QGIS; publicação de mapas na internet (através, por exemplo, de WMS), o programa tem ainda uma consola *Python* integrada onde é possível criar *scripts* de automação de tarefas.

Durante o desenvolvimento desta dissertação foi utilizada esta ferramenta, as principais razões que levaram a esta escolha foram o fato de ser gratuita, existir uma grande quantidade de *plugins*, oferecer as funcionalidades necessárias, como a possibilidade de criar uma interface gráfica para a aplicação desenvolvida.

2.3.2 ArcGIS

ArcGIS é outro programa GIS desenvolvida pelo *Environmental System Research Institute* (ESRI), carece de uma licença de utilização.

O *ArcGIS* oferece ferramentas de análise espacial, permitindo a conexão de dados, que de outra forma pareciam não relacionados, através da análise de padrões e de modelos classificativos. Este GIS pode ser utilizado com *stand-alone* ou através da sua combinação com outras plataformas, permitindo criar, utilizar e partilhar mapas em diferentes dispositivos. Uma das funcionalidades interessantes deste GIS é o fato de permitir a visualização de dados em tempo real, o que permite a monitorização ativa em áreas como a deteção de incêndios. É possível a visualização de imagens 3D, sendo possível a aquisição de dados dos repositórios de imagens de satélite de todo o mundo.

2.3.3 OSGeo4W

OSGeo4W é uma distribuição para o *Windows* de um conjunto de programas GIS, entre eles encontram-se o QGIS, o GDAL/OGR e o GRASS. Depois de instalada, esta distribuição fornece a '*OSGeo4W Shell*' que é uma consola onde se encontram instaladas todas as bibliotecas do OSGeo4W. Nesta dissertação esta ferramenta é utilizada para executar os ficheiros *Python* criados, uma vez que dependem de algumas destas bibliotecas, como é o caso do GDAL, que permite a transformação entre vários formatos de vetores e *rasters*.

3 Estado de Arte

No estado da arte são apresentados alguns dos métodos mais utilizados na área da detecção remota, nomeadamente para classificação de imagens de satélite. Segundo (Jordi Inglada, Marcela Arias, Benjamin Tardy, Olivier Hagolle & David Morin, Gérard Dedieu, Guadalupe Sepulcre, Sophie Bontemps, Pierre Defourny, 2015) o típico processo para a produção de mapas de ocupação de solo contém quatro passos:

1. Segmentação da imagem (no caso de ser utilizada uma aproximação ao objeto);
2. Extração de atributos da imagem;
3. Classificação;
4. Fusão e pós-processamento;

Neste capítulo são dados a conhecer alguns dos métodos para cada um destes passos, primeiro são apontadas as diferenças das abordagens ao pixel e ao objeto, bem como várias vantagens e desvantagens da sua utilização na classificação destas imagens. São apresentados vários tipos de algoritmos de segmentação, os atributos mais utilizados nesta área e os tipos de classificadores mais comuns em projetos semelhantes.

3.1 Pixel contra Objeto

A abordagem baseada no pixel é o primeiro e mais óbvio método de classificação de imagens de satélite, onde a cada pixel da imagem é atribuída uma Classe. A utilização deste método facilita a obtenção da precisão do classificador, basta calcular a

percentagem de área corretamente classificada (Ye, Pontius, & Rakshit, 2018). A aplicação desta abordagem traz algumas limitações, primeiro a dificuldade em alinhar um pixel no mapa com a mesma posição no mapa de referência utilizado (Ye et al., 2018). Segundo, um único pixel não consegue representar informações espaciais complexas do objeto a que pertence, nomeadamente, tamanho, forma, textura e contexto (Blaschke et al., 2014), estas informações são utilizadas pelo humano de uma forma automática. E finalmente o problema do sal e pimenta, este problema ocorre com maior frequência nas imagens de alta resolução, onde grandes variações das medições espectrais de diferentes pixels pertencentes à mesma classe levam à grande dificuldade na correta classificação do mesmo (G. Zhang, Jia, & Kwok, 2012).

Por outro lado, numa abordagem baseada no objeto, também conhecida como abordagem por polígonos (Ye et al., 2018), tem em conta segmentos homogêneos da imagem, cada segmento possui os seus próprios atributos (tamanho, forma, etc.) e consequentemente a sua própria classificação. Este método é mais recente e ainda se encontra em desenvolvimento, no entanto é cada vez mais utilizado, substituindo o método anterior (Ye et al., 2018). Abordar o estudo da classificação de solo através da classificação de objetos tem várias vantagens:

- Aumento da variabilidade espectral de elementos da mesma classe, isto permite corrigir, de certa forma, o problema do sal e pimenta;
- O método toma em consideração características espaciais do objeto a classificar, como o tamanho, forma ou textura. A utilização deste tipo de característica são de senso comum para um humano, e são um dos fatores que diferenciam esta abordagem da anterior.

Apesar das evoluções na utilização desta abordagem, ainda persistem alguns problemas relativos ao mesmo, nomeadamente:

- A segmentação consiste na divisão da imagem captada em grupos de pixels (objetos ou polígonos) vizinhos de acordo com um determinado critério. A qualidade dos resultados finais da classificação depende diretamente da qualidade da segmentação realizada. (Ye et al., 2018)
- A escolha de atributos espaciais relevantes para a correta classificação de cada objeto tem um nível de dificuldade elevado.
- Apesar do acesso às características espaciais do objeto é ainda difícil a sua ligação com objetos do mundo real. (Ye et al., 2018)
- A avaliação do classificador torna-se difícil um vez que não está em causa apenas a classe resultante do objeto, como a avaliação do seu tamanho, forma e

posição. Existem vários métodos que tentam implementar uma métrica que reflita a avaliação da segmentação através da utilização da área, perímetro ou do número de segmentos resultantes (G. Meinel & Leibniz, 2004). Uma lista com alguns dos modelos utilizados para avaliação da qualidade da segmentação encontra-se em (Ye et al., 2018).

Na figura 3.1 é possível visualizar as imagens resultantes da classificação da imagem aérea (à esquerda) através da abordagem do pixel (ao centro) e do objeto (à direita). A abordagem por objeto permite a criação de áreas mais homogêneas e de mais fácil leitura.




Figura 3.1 - Comparação de classificação da imagem original (esquerda) numa abordagem ao nível do pixel (centro) e ao objeto (direita). Retirado de <https://frameworks.ced.berkeley.edu>

3.2 Segmentação

Segmentação é o processo de agregação de vários pixéis vizinhos segundo determinado critério com o objetivo da criação de objetos (ou polígonos). A qualidade da segmentação realizada está diretamente relacionada com a qualidade do classificador gerado (G. Meinel & Leibniz, 2004), uma vez que a classificação é baseado no objeto, objetos com características geométricas diferentes da solução pretendida levam, na maioria dos casos, a zonas de pixéis com incorreta classificação. Associado aos algoritmos de segmentação existem os problemas de excesso de segmentação, onde são gerados demasiados segmentos e com tamanhos demasiado pequenos, e de pouca segmentação onde o resultado da segmentação dá origem a polígonos demasiado grandes e em pequeno número. Problemas de excesso de segmentação são menos graves, uma

vez que aos objetos vizinhos de tamanho reduzido podem ser atribuídos a mesma classe. Por outro lado, problemas de pouca segmentação podem dar a origem a polígonos grandes com regiões pertencentes a classes distintas, isto vai dar origem a zonas de classificação incorreta. Existem vários tipos de algoritmos para o processo de segmentação de imagem, na figura 3.2 encontra-se um exemplo de uma imagem aérea segmentada, através da utilização do programa *eCognition*, um *software* de imagens baseado em objetos.




Figura 3.2 - Exemplo de imagem segmentada, extraída através do *software eCognition*. Retirada de (Benz, Hofmann, Willhauck, Lingenfelder, & Heynen, 2004)

3.2.1 Baseado em pontos

Os algoritmos de pontos baseiam-se na procura de elementos de acordo com um determinado critério de semelhança, ou seja, que apresente valores determinados atributos semelhantes. O critério de segmentação mais utilizado é a homogeneidade, onde são comparadas determinadas características de dois objetos (como o nível de cinzento ou alguma combinação de vários atributos distintos) (Schiewe, 2002).

3.2.2 Baseado em contornos

Estes algoritmos tiram partido de métodos de deteção de objetos, como o filtro de *Sobel*, e de algoritmos geradores de contornos, os contornos obtidos são depois utilizados como as fronteiras/arestas do objeto.

3.2.3 Baseados em regiões

Os métodos de regiões baseiam-se na procura de objetos com níveis de semelhança dentro de um determinado *threshold*, de acordo com esse valor dois objetos podem fundir-se ou formar dois objetos distintos, o valor de *threshold* pode ser ajustado manualmente, ou pode depender de outros valores como o tamanho desejado dos segmentos ou o número de segmentos pretendido. Estes algoritmos podem ser de aumento de região onde cada elemento inicial é um pixel da imagem, e de acordo com a sua semelhança vão sendo agrupados, ou de separação de regiões onde o elemento inicial é toda a imagem, e em cada iteração o elemento é dividido em elementos mais pequenos. Para combater o problema de excesso ou carência de segmentação dos métodos anteriores, existe ainda a aproximação dividir e juntar (*Split & Merge*), que combina as duas técnicas anteriores, neste caso sempre que existe uma divisão de um elemento, é posteriormente testada a possível junção de elementos vizinhos (Schiewe, 2002).

3.2.4 Bacias hidrográficas

O algoritmo das bacias hidrográficas (Transformada de watershed) permite a criação de segmentos a partir do mapa topográfico da imagem, cada polígono é gerado através do agrupamento de pixéis cujo mínimo de altitude mais próximo seja comum, desta forma cada polígono contém apenas um ponto mínimo local. Este método apresenta muitas vezes o problema de excesso de segmentação uma vez que podem existir pixéis de altitude mínima próximos, este problema pode ser minimizado com a utilização de filtros morfológicos onde é realizado uma dilatação seguida de uma erosão (G. Zhang, Jia, & Kwok, 2011).

3.3 Extração de atributos

Neste subcapítulo são apresentados alguns dos atributos mais utilizados para a classificação de imagens de satélite: as utilizadas numa abordagem baseada no pixel, baseada no objeto e através de algoritmos de *deep learning*. Por fim, são ainda dados a conhecer alguns métodos de avaliação de qualidade de cada um dos atributos utilizados.

3.3.1 Análise ao nível do Pixel

3.3.1.1 Bandas

As bandas são os valores diretamente adquiridos através dos valores da leitura dos sensores do satélite. No caso do *Sentinel-2* são disponibilizadas 13 bandas que podem ser utilizadas como atributos, estas bandas apesar de já poderem apresentar bons resultados, são também utilizadas para cálculo de índices.

3.3.1.2 NDVI

Normalized Vegetation Index (NDVI) é um dos índices mais utilizados nesta área científica, é sabido que para a realização da fotossíntese as plantas verdes absorvem radiação vermelha (R) e refletem na banda do infravermelho próximo (NIR) (Joshua Stevens, Jennifer M. Smith, 2018), e com base neste efeito foi criado o índice *NDVI* que calculado por:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (3.1)$$

Este índice apresenta valores entre -1 e 1, sendo que valores mais próximos de 1 representam áreas densas de vegetação saudável. Valores perto de -1 indicam presença de nuvens, neve ou água, enquanto que valores próximos de 0 simbolizam terrenos rochosos e/ou sem vegetação (Joshua Stevens, Jennifer M. Smith, 2018). Este índice é muito utilizado para monitorização da vegetação à escala global, no entanto é bastante sensível ao efeito a perturbações devido ao brilho emitido pelo solo e atmosféricas (Brecht, 2018).

3.3.1.3 EVI

Enhanced Vegetation Index (EVI) é um método alternativo ao NDVI que tenta corrigir os problemas do índice anterior, desta forma são utilizados os parâmetros C1, C2 e L como fatores que minimizam os vários tipos de perturbação, juntamente com as bandas vermelha (R), verde (G) e azul (B).

$$EVI = 2,5 * \frac{NIR - R}{NIR + C1 * R - C2 * B + L} \quad (3.2)$$

Os valores mais utilizados para os parâmetros segundo (Xue & Su, 2017) são: L=1, C1=6 e C2=7,5

3.3.1.4 NDWI

Normalized Difference Water Index (NDWI) foi inicialmente proposto em (Gao, 1996) com o objetivo de detetar a presença de água em plantas, este índice é me-

nos sensível ao ruído atmosférico que o *NDVI*. O cálculo do *NDWI* é dado apresentado em (Xu, 2006) por:

$$NDWI = \frac{G - NIR}{G + NIR} \quad (3.3)$$

Onde G, o valor dado pela banda correspondente à cor verde, e NIR ao infravermelho próximo. Este índice apresenta valores positivos na presença de áreas de vegetação, e pelo contrário valores negativos em zonas sem vegetação. Tal como o índice anterior, estes valores têm perturbações devido à reflexão do solo (Gao, 1996).

3.3.1.5 SAVI

Soil Adjusted Vegetation Index (SAVI) vem tentar corrigir as perturbações do solo. Segundo (Epiphanyo & Huete, 1995), o índice é calculado através da expressão:

$$SAVI = (1 + L) \frac{NIR - R}{NIR + R + L} \quad (3.4)$$

Onde L é constante e igual a 0,5.

Os artigos (Xue & Su, 2017) e (Brecht, 2018) apresentam uma listagem de inúmeros índices que poderão ser estudados em maior detalhe durante a realização do projeto.

3.3.1.6 Transformações do espaço de representação de cores

O espaço de representação de cores que estamos mais familiarizados é o *Red-Green-Blue (RGB)*, no entanto esta pode não ser a melhor forma de utilização das bandas das imagens de satélite. É possível transformar este espaço permitindo, por exemplo, separar os efeitos da luz no objeto, tentando combater o problema das sombras (Yu et al., 2006). Transformações deste espaço podem criar novas representações que permitem o melhoramento dos atributos da cor para efeitos de classificação. Em (Kalyankar & Nanded, 2011) encontra-se uma compilação de várias transformações utilizadas no campo da deteção remota, segundo os autores as transformações *IHS5* e *YIQ* obtiveram melhores resultados.

A transformação Intensidade-Tonalidade-Saturação (*IHS5*) é composta pela intensidade ou brilho que se refere à quantidade de luz do pixel, a tonalidade é o comprimento de onda da cor do pixel e a saturação é a pureza da cor (Y. Zhang & Hong, 2005), é calculada através de:

$$\begin{bmatrix} I \\ v_1 \\ v_2 \end{bmatrix} = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/\sqrt{6} & 1/\sqrt{6} & -2/\sqrt{6} \\ 1/\sqrt{2} & -1/\sqrt{2} & 0 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad H = \tan^{-1} \left(\frac{v_2}{v_1} \right) \quad S = \sqrt{v_1^2 + v_2^2} \quad (3.5)$$

O *YIQ* é uma transformação direta do *RGB*, este tenta tomar partido da alta sensibilidade do olho humano da luminância, que é a quantidade de luz que é emitida ou refletida de um determinado objeto, quando comparada com a tonalidade ou a saturação. O fator Y simboliza, assim, a luminância de cor é calculado através do *RGB* pesado da sensibilidade do olho humano para cada um destes fatores. Enquanto que o I e o Q representam a crominância, sendo o I a diferença do vermelho e o ciano, e o Q o magenta menos o verde (Kalyankar & Nanded, 2011). O *YIQ* pode ser calculado por:

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,144 \\ 0,596 & -0,274 & 0,322 \\ 0,211 & -0,523 & 0,312 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.6)$$

3.3.1.7 Dados auxiliares

Dados auxiliares são atributos que são obtidos através de outros métodos, mas que representam informação relevante para a construção do classificador. Algumas características geográfica, como a altitude, inclinação, tipo de terreno e a distância ao curso de água mais próximo, podem ser um fator determinante para uma melhor classificação, principalmente quando se trata de classificação de tipos de vegetação (Yu et al., 2006).

3.3.1.8 Atributos de *Haralick*

Os atributos de *Haralick*, inicialmente propostos em (Haralick, 1979), contêm informações relativas à textura da imagem, através destes é possível identificar zonas de terreno com níveis de cor mais irregular, nestes casos existem maior diferença de cor entre os pixéis vizinhos, ou seja, maior contraste, ou zonas mais regulares onde existem menos diferença. Zonas de floresta são geralmente irregulares, enquanto que lagos ou descampados são normalmente regulares. A adição deste tipo de atributos tem um aumento significativo na precisão do modelo (Hall-beyer, 2018).

Para o cálculo destes atributos de uma imagem, é calculada a *Gray Level Correlation Matrix* (GLCM), a matriz representa relações entre pares de pixéis. Os atributos são depois obtidos através de operações como somas ponderadas desta matriz. Este método permite retirar um valor representativo da textura para toda a imagem, no entanto, este valor não nos traz informação relevante para o classificador, tendo maior interesse a criação de uma nova imagem que reflita os níveis de textura em cada ponto da imagem original. Com este fim, para cada um dos pixéis a analisar da imagem original é calculada uma destas matrizes, sendo utilizados os pixéis que se encontram

dentro de uma janela centrada nesse mesmo pixel a analisar. A matriz é depois utilizada para o cálculo do valor dos atributos nesse pixel. O método em janela deslizante pode assim ser utilizado para extração da textura de toda a imagem (G. Zhang et al., 2011). O fato da matriz ser calculada para cada um dos pixels da imagem dá origem à utilização de muita memória. Tomando como exemplo a imagem 2A do *Sentinel*, temos uma imagem de 10.980×10.980 , ou seja, 120.560.400 pixels, considerando que cada matriz tem a dimensão de 16×16 , temos no total $120.560.400 \times 16 \times 16 = 30.863.462.400$ valores. É, ainda comum o cálculo de várias matrizes para cada um dos pixels de imagem, variando alguns dos seus parâmetros como a distância ou o ângulo, aumentando multiplicativamente este valor. É, por isso, importante realizar estes cálculos dividindo a imagem em várias partes.

Como referido anteriormente, a matriz é uma representação da relação de pares de pixels da imagem, sendo que cada par contém um pixel de referência e um pixel vizinho. Cada pixel da janela será considerado o pixel de referência iterativamente. O seu pixel vizinho correspondente é calculado através de dois parâmetros que devem ser selecionados previamente, a distância entre os dois pixels também designada por *offset*; e o ângulo entre eles. Por exemplo, se for considerado uma distância de 1 e um ângulo de 0° , o pixel vizinho é o pixel à direita do pixel de referência. Para melhorar os dados relativos à textura da imagem é, por vezes, realizado o cálculo da matriz para várias combinações destes parâmetros, sendo os valores dos atributos finais a média dos valores calculados para cada uma das matrizes. Os valores das direções normalmente utilizados são 0° , 45° , 90° e 135° , desta forma é facilmente calculado qual a posição do pixel vizinho.

A matriz é, inicialmente, quadrada, nula e com uma dimensão correspondente ao valor de níveis de cinzento distintos que a imagem pode tomar, a utilização de um número elevado de níveis dá origem a matrizes muito grandes, o que origina problemas de memória. A quantização em 16 níveis é, na maior parte das aplicações suficiente (Albregtsen, 2008). É assim necessária uma normalização e discretização previa dos valores dos pixels da imagem. Cada linha da matriz corresponde ao valor do pixel de referência, enquanto que cada coluna representa o valor do pixel vizinho. Um exemplo da construção da GLCM encontra-se na figura 3.3.




Figura 3.3 - Exemplo do processo de criação da GLCM para 8 níveis de cinzen-
to. À esquerda a imagem onde será extraída a matriz; à direita a GLCM criada, a ver-
melho encontram-se os valores correspondentes aos pixels de referência e a verde os
vizinhos. Retirado de <https://www.imageprocessing.com/2019/04/grey-level-co-occurrence-matrix-glcmm-in.html>

Depois de iniciada a matriz, cada pixel da janela é considerado iterativamente como o pixel de referência. É incrementado em uma unidade o valor da célula da matriz de cada par (referência, vizinho) na posição correspondente da matriz. Na primeira iteração é utilizado o primeiro pixel da imagem de valor 1, tendo o correspondente vizinho o valor 2, será incrementada a célula da matriz (1,2) (esta representada a amarelo na figura 3.3).

Para o cálculo dos atributos é necessária que a matriz seja simétrica e normalizada. Para a simetria da matriz é, normalmente, utilizado o método que consiste em incrementar o valor da matriz contrário ao par encontrado, para o exemplo anterior a célula (2,1) também seria incrementada, desta forma estão a ser adicionados à matriz não só o par (referência, vizinho) com o (vizinho, referência) representando a transição com direção oposta. Este método vem também permitir que ao utilizar apenas os valores dos ângulos 0°, 45°, 90° e 135° sejam representados na GLCM as direções 180°, 225°, 290°, 335° tendo a informação da textura retirada em redor de todo o pixel, sendo bastante mais rápido que o cálculo individual de todas as direções. Para a normalização, após o cálculo da matriz, cada uma das células deve ser dividida pela soma de todas as células.

Nesta fase, depois da GLCM criada, é possível constatar que valores da diagonal principal da matriz com valores mais elevados representam imagens mais regulares, isto porque os valores da diagonal correspondem a pares onde não existe diferença entre o valor do pixel de referência e o seu vizinho. Por outro lado, quando os valores da diagonal são inferiores estamos perante uma imagem mais irregular. Os valores dos atributos que podem ser extraídos da imagem são valores que tentam retratar o comportamento deste tipo de analogia em apenas um valor, sendo que cada atributo tenta descrever estas características de maneira diferentes. Alguns dos atributos que podem ser extraídos através da GLCM são enumerados de seguida. Para as fórmulas do cálculo dos atributos são considerados i e j o valor da linha e coluna, respetivamente; $P_{i,j}$ o valor da célula P na posição (i,j) e o valor N o número de linhas ou colunas.

Contraste: Para o cálculo do contraste é utilizada a soma dos valores das células da matriz ponderada pela distância à diagonal. Os valores da diagonal, onde estão representados os valores sem contraste são ponderados de zero, pelo que não entram no resultado final.

$$\sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2 \quad (3.7)$$

Dissimilaridade: Este cálculo é semelhante ao anterior, no entanto, os pesos da distância à diagonal principal variam linearmente.

$$\sum_{i,j=0}^{N-1} P_{i,j}|i-j| \quad (3.8)$$

Homogeneidade: Este atributo retrata a textura da imagem de forma contrária aos anteriores, sendo dado mais peso às células mais próximas da diagonal.

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2} \quad (3.9)$$

Segundo momento angular (ASM): Este atributo tenta retratar a repetibilidade da textura da imagem. O seu valor é elevado quando os valores do par (referência, vizinho) é repetido muitas vezes, isto acontece em imagens com níveis de cinzento mais ordenados. Imagens de ruído aleatório são um exemplo de um valor de ASM baixo. Na figura

3.4 encontra-se um exemplo de imagem com ASM baixo (à esquerda) e de um ASM elevado (à direita).




Figura 3.4 - Exemplo de imagem com baixo ASM (à esquerda) e alto ASM (à direita). Imagem criada através da plataforma *Processing*

O ASM pode ser calculado através da equação 3.10.

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (3.10)$$

Energia: A energia é um atributo que é calculado através do ASM.

$$\sqrt{ASM} \quad (3.11)$$

Correlação: O atributo correlação mede a dependência linear dentro dos valores da GLCM, ou seja, tenta encontrar uma certa previsibilidade ou relação entre o valor do pixel de referência e o seu vizinho. O atributo utiliza a média e a variância da GLCM representadas na equação 3.12 para o seu cálculo final da equação 3.13. Janelas que contenham pixels com o mesmo tipo de terreno têm, normalmente, valores de correlação mais elevados. Este atributo é um cálculo bastante diferente dos restantes, o que o torna independente, isto pode levar a um aumento de informação extraída da imagem e consequente aumento da *performance* do classificador (Hall-beyer, 2018).

$$\mu_i = \sum_{i,j=0}^{N-1} i(P_{i,j}) \quad \sigma_i^2 = \sum_{i,j=0}^{N-1} P_{i,j}(j - \mu_i)^2 \quad (3.12)$$

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (3.13)$$

3.3.1.9 Atributos temporais

Por vezes é necessário fazer uma amostra do mesmo local periodicamente, formando um *dataset* mais complexo, onde é adicionada a variável temporal, nestes casos podemos ter todos os atributos identificados anteriormente, mas recolhidos em instantes diferentes. Este tipo é muito utilizado em estudos de deteção de mudança do tipo de terreno (Singh, 2010).

3.3.2 Análise baseada em Objetos

3.3.2.1 Estatísticas do pixéis contidos no objeto

Atributos utilizados numa abordagem baseada no pixel podem ser também usados numa abordagem baseada em objetos, através da utilização de métricas como a média ou o desvio padrão dos valores dos pixéis contidos no objeto. No estudo apresentado em (Yu et al., 2006) foram utilizadas a média e o desvio padrão, dos valores dos atributos de todos os pixéis contidos no mesmo objeto. Como atributos foram usados os valores das bandas, elevação, índices, entre outros. Em (Immitzer et al., 2016) foram utilizados a média, desvio padrão, mínimo, mediana, máximo, percentil de 25% e de 75% das bandas 2, 3, 4 e 8 do *Sentinel-2*.

3.3.2.2 Atributos geométricos

Uma das principais vantagens da utilização de uma abordagem baseada no objeto é o fato de se ter acesso aos atributos geométricos do polígono a classificar, nomeadamente, a sua forma, tamanho, largura, etc. Estas características são utilizadas de uma forma automática pelo humano, por exemplo para identificar um edifício, no entanto são características difíceis de retirar informação relevante.

No artigo (Yu et al., 2006), são utilizados como atributos geométricos a área, largura, comprimento, compacidade, ajuste retangular, perímetro, índice de forma, densidade, direção principal, assimetria, número de arestas, desvios padrão e média do comprimento das arestas e comprimento da maior aresta.

3.3.3 Análise baseada em *Deep Learning*

Deep Learning é um conceito muito falado nos dias que correm, consiste na utilização de redes neuronais com um número significativo de camadas que conseguem representar dados com vários níveis de abstração (Lecun, Bengio, & Hinton, 2015). É possível utilizar as primeiras camadas de um modelo previamente treinado extraíndo assim características que poderão ser úteis na criação do classificador de imagens de satélite (Penatti, Nogueira, & Dos Santos, 2015). Esta ideia foi também estudada em

(Romero, Gatta, & Camps-Valls, 2016), no entanto a rede neuronal foi treinada num modelo não supervisionado, onde foi estimulada a variação da saída de forma a obter atributos com maior importância. O tipo de abordagem supracitado é mais utilizado para classificação de imagens, não propriamente de pixels ou objetos.

3.3.4 Seleção de atributos

A seleção de atributos tem como principal objetivo a diminuição do número de atributos a utilizar pelo classificador não reduzindo a qualidade do resultado obtido, permitindo diminuir significativamente o tempo de computação necessário para a criação do modelo (Yu et al., 2006). Além disso, a utilização de um maior número de atributos nem sempre leva a um melhor resultado, podendo originar problemas de *overfitting* como apresentado em (Yu et al., 2006) ou (Hall, 1999). Em alguns casos a redução do número de atributos leva a um aumento na precisão do modelo, uma vez que alguns dos algoritmos de classificação utilizados são afetados por informação irrelevante ou redundante (Hall, 1999).




Figura 3.5 – Classificação de importância dos atributos e precisão vs número de atributos. Retirada de (Yu et al., 2006)

Por outro lado, a diminuição do número de atributos torna a informação mais compacta e de fácil leitura. No artigo (Yu et al., 2006) foram testados vários conjuntos de atributos distintos, na figura 3.5 é possível verificar que a precisão do classificador aumenta à medida que são adicionados atributos, no entanto a partir dos vinte atributos

tos a precisão começa a diminuir. De notar que os atributos foram previamente ordenados por ordem de “importância”, existindo dois tipos de algoritmos que permitem este tipo de ordenação:

- Os *wrappers* que tomam partido do algoritmo de aprendizagem utilizado, analisando a precisão de vários subconjuntos de atributos. Este método é muito dispendioso computacionalmente, uma vez que o algoritmo de aprendizagem é chamado repetidamente (Mark A. Hall, 1998);
- Os filtros calculam a relevância de cada característica independentemente do algoritmo de classificação utilizado. Este método é executado antes de qualquer tipo de treino, e, na maioria dos casos, utiliza todo o conjunto de treino. Este método é mais utilizado, uma vez que é muito mais rápido, principalmente em casos que apresentem conjuntos de treinos de grande dimensão.

Selecionador de atributos baseado na correlação (*CFS*) (Hall, 1999) é um algoritmo tipo filtro que ordena os atributos com base na sua forte correlação com a classe (corrigindo a irrelevância), e fraca correlação com outros atributos (corrigindo a redundância).

Classificação e Regressão em árvore (*CART*) é um algoritmo de geração de árvores de decisão, que, no entanto, pode ser utilizado como uma ferramenta para ordenação da importância de cada atributo. Este algoritmo tenta minimizar a impureza de cada ramo da árvore e utiliza métricas como a entropia ou o *ginni*. Este método foi utilizado em (Yu et al., 2006) e (Bittencourt & Clarke, n.d.).

Uma lista de muitos outros métodos de seleção de atributos encontra-se disponível no artigo (Langley, 1994).

3.4 Classificação

Classificação é o processo que, tendo um determinado conjunto de atributos de entrada, é estimada qual a Classe resultante. Esta estimativa pode ter como base exemplos vistos anteriormente (aprendizagem supervisionada), ou o classificador pode tentar agrupar instâncias com base nas semelhanças entre os seus atributos (aprendizagem não supervisionada). Neste capítulo são dadas a conhecer algumas das técnicas de *machine learning* mais utilizadas para classificação de imagens aéreas da superfície terrestre.

3.4.1 Probabilidade máxima

A classificação do tipo probabilidade máxima é uma das mais utilizadas para processamento de imagem na área da detecção remota, e tem por base a função de distribuição Gaussiana. Os parâmetros dessa função são obtidos *a priori* através dos exemplos previamente fornecidos ao algoritmo, sendo, assim, um algoritmo de aprendizagem supervisionado (Foody, 1992). Após o cálculo desses parâmetros, sabendo o valor dos atributos da instância a ser classificada é calculada a probabilidade de pertença da mesma a cada uma das classes possíveis, o resultado da classificação é dado pela classe com maior probabilidade. Este método pode ser computacionalmente pesado, principalmente quando utilizado em imagens com resolução espacial mais elevada.

3.4.2 *Random Forest*

O algoritmo da árvore de decisão consiste na divisão sucessiva do *dataset* inicial em subconjuntos uniformes, onde cada nó da árvore representa um determinado critério de divisão das instâncias. Os critérios são escolhidos de forma a minimizar a impureza do conjunto resultante, aumentando a certeza de pertença dessa instância à classe resultante. O *random forest* é um método onde são geradas várias árvores de decisão com base em conjuntos de atributos distintos selecionados aleatoriamente e a classificação da instância é dada pela classe mais votada de todo o conjunto de árvores geradas (Pal, 2005).

3.4.3 Máquina de suporte de vetor

Máquina de suporte de vetor é um método de aprendizagem estatístico que tem como objetivo a criação de fronteiras lineares que otimizem a separação de instâncias de diferentes Classes. A margem é dada pela soma das distâncias entre a instância mais próxima de cada classe e a sua fronteira, este método maximiza a margem através de algoritmos como a programação quadrática (Pal, 2005). O método funciona bastante bem quando perante o caso onde os atributos são linearmente separáveis, no entanto, no caso contrário para além da maximização da margem é ainda minimizado o número de casos incorretamente classificados, o que torna ainda assim este método frequentemente utilizado na detecção remota.

3.4.4 Redes Neurais

As redes neurais são um método inspirado nas redes de neurónios que fazem parte da biologia do cérebro animal. Para criação da rede neuronal é necessária a escolha de uma arquitetura com um determinado conjunto de neurónios e um determinado número de camadas. A camada de entrada da rede recebe o valor dos atributos, estes valores são depois propagados para as camadas seguintes através de somas ponderadas pelo peso de cada uma das ligações sinápticas. Este é um método supervisionado que necessita de um conjunto de treino com instâncias que representem corretamente todo o universo de possibilidades, fundamentais para a obtenção dos pesos otimizados. Os pesos são alterados iterativamente colocando à entrada os valores dos atributos das instâncias do conjunto de treino e comparando a saída da rede com a saída esperada, é depois utilizado um algoritmo de cálculo dos novos valores dos pesos, sendo o mais utilizado o *backpropagation* (Castelluccio, Poggi, Sansone, Verdoliva, & Aug, 2015).

3.4.5 Lógica difusa

A lógica difusa é um método muito utilizado na deteção remota. Para cada par classe-atributo é gerada uma função de pertença baseada na distribuição dos valores desse mesmo atributo observados nos exemplos do conjunto de treino pertencentes a essa Classe. Esta distribuição pode ser aproximada a uma distribuição Gaussiana através da média e desvio padrão (Ayhan & Kansu, 2012), ou podem ser utilizados outros tipos de distribuição. É ainda necessário definir um conjunto de regras que permita fazer a ligação da entre o conjunto de funções de pertença de cada um dos atributos a cada uma das classes, geralmente estas regras são definidas por um especialista na área de aplicação do método, ou por regras mais diretas como em (Mora et al., 2017).

Utilizando os valores dos atributos da instância a classificar e cada uma das funções de pertença correspondentes é possível calcular o nível de pertença de cada um dos atributos para cada uma das classes. Por fim é necessário fazer a agregação destes níveis de pertença de forma a ter o nível de pertença da instância a cada classe. Wm (Santos, Mora, Ribeiro, & Silva, 2016) são comparados os operadores de agregação: média, mínimo, FIMICA e UNIFORM.

3.4.6 K-vizinhos mais próximos

O algoritmo K-vizinhos mais próximos é um método que utiliza as K instâncias do conjunto de treino com maior nível de semelhança da instância a classificar. O nível de semelhança é avaliado por uma métrica de distância, sendo as mais utilizadas segundo (G. Zhang et al., 2012) a distância Euclidiana, a interseção de histogramas e a χ^2 . A classificação final é dada pela classe mais frequente dentro das K instâncias mais semelhantes encontradas.

4 Trabalho Desenvolvido

O trabalho de suporte a esta dissertação foi uma ferramenta para a criação semi-automática de conjuntos de treino. Neste capítulo será apresentado uma descrição detalhada dessa aplicação, inicialmente é descrita a organização os ficheiros criados, seguindo-se uma descrição de como foram produzidos. É ainda importante salientar que se encontra em Anexo no final deste documento um manual para instalação e utilização do código do trabalho desenvolvido.

4.1 Descrição da aplicação

A aplicação desenvolvida permite a criação semi-automática de conjuntos de treino para posterior criação de classificadores. Para tal, é inicialmente recebido um conjunto de imagens do *Sentinel-2*, e são dados a escolher quais os atributos a extrair da imagem. É possível a seleção de índices, transformação do espaço de cores e texturas, sendo ainda extraídas todas as bandas recolhidas pelo *Sentinel-2*, bem como um mapa onde estão os polígonos da COS 2015.

Após a extração de todos os atributos, é possível a execução da interface principal da aplicação. Nesta interface encontra-se uma área de desenho onde estão contidas as imagens recolhidas pelo *Sentinel-2*. O papel do utilizador é a seleção de polígonos representativos de cada uma das Classes em estudo, esta seleção pode ser feita através

do desenho manual de polígonos na área de desenho ou através da adição de polígonos diretamente extraídos da COS. Os polígonos selecionados darão origem ao atributo “Classe”, a ser classificado através das técnicas de *machine learning*.

4.2 Organização dos ficheiros da aplicação

Durante o desenvolvimento da aplicação foi criada uma pasta com todos os ficheiros necessários para o correto funcionamento da mesma. Um diagrama em árvore da organização dos ficheiros desta pasta encontra-se na figura 4.1. A pasta principal da aplicação está dividida em sub-pastas, cada uma com os ficheiros para determinada função.

```
C:\.
|
| app.py
| create_workspace.py
| estilo_cos.qml
| estilo_cos_transparent.qml
| interface_load.py
| launch.bat
| polygon.py
| readme.html
| resources.qrc
| resources_rc.py
| setup.bat
|
+---COS_Portugal
|   cos_portugal.dbf
|   cos_portugal.prj
|   cos_portugal.qpj
|   cos_portugal.shp
|   cos_portugal.shx
|
+---setup
|   numpy-1.16.3+mkl-cp27-cp27m-win_amd64.whl
|
\---ui
|   dataset_generation.ui
|   main.ui
|   main_save.ui
|   polyDialog.ui
|   resources.qrc
|
\---icons
|   agri.png
|   corp_ag.png
|   esp_desc.png
|   flore.png
|   matos.png
|   orange.jpg
|   past.png
|   sist_agro.png
|   terr_arti.png
|   zonas_hum.png
```

Figura 4.1 – Diagrama em árvore com a distribuição dos ficheiros na pasta da aplicação

- **Principal** – Na pasta principal da aplicação encontram-se os ficheiros necessários para executar o programa, bem como os ficheiros para configurar o sistema;
- **COS-Portugal** – Ficheiros onde são guardados os polígonos da COS de todo o território de Portugal;
- **Setup** – Ficheiros utilizados na instalação das bibliotecas necessárias para correr o programa;
- **Ui** – Ficheiros onde estão representados todas as interfaces gráficas
- **Ui/icons** – Imagens onde se encontram os icons, utilizados para legendar cada uma das classes;

4.3 Cos_portugal

Este conjunto de ficheiros tem contida a informação relativa à COS de todo o território de Portugal, sendo, posteriormente, utilizados pelo ficheiro *Python* “create_workspace.py”. Os polígonos são, inicialmente, descarregados em ficheiros que dividem o território no sistema NUTS III (Nomenclatura das Unidades Territoriais para Fins Estatísticos), num total de 25 sub-regiões. O catálogo de ficheiros para disponíveis encontra-se na página *web* da DGT (<http://mapas.dgterritorio.pt/geoportal/catalogo.html>). Todos os ficheiros obtidos para realização desta dissertação foram adquiridos através do serviço INSPIRE ATOM, onde são disponibilizados os mapas das unidades administrativas, COS 2015, 2010 e 2007, modelo geóide, modelo digital de terreno 50M e CLC 2000, 2006 e 2012.

Os ficheiros foram obtidos através do *plugin* “*Inspire Atom*” disponibilizado abertamente no QGIS, um exemplo da utilização deste *plugin* encontra-se na figura 4.2.

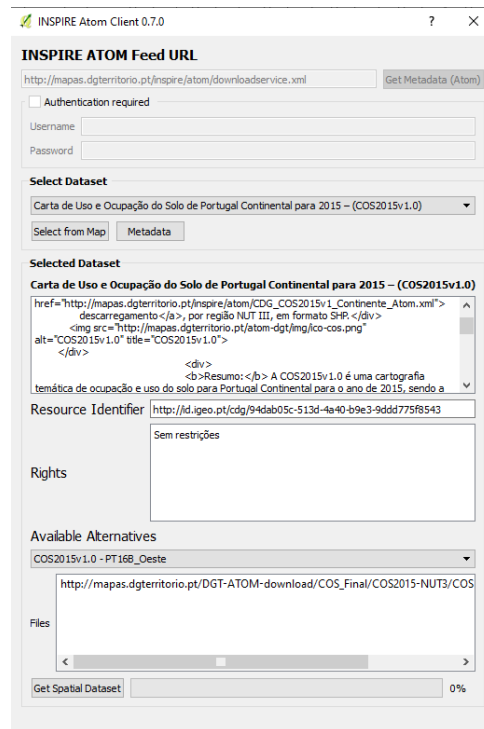


Figura 4.2 – Extração dos dados da COS para a sub-região Oeste utilizando o *plugin “Inspire Atom”*

Numa fase posterior foi necessária a criação de um ficheiro que juntasse a informação de todos os ficheiros enumerados anteriormente. Os ficheiros anteriores foram assim agrupados, utilizando a função do QGIS *“Vector>Data Management Tools>Merge Vector Layers”*, que permite fazer a fusão de polígonos guardados em camadas do QGIS distintas, criando uma nova camada onde estão presentes todos os polígonos anteriores.

4.4 Ficheiros ui

Os vários ficheiros do tipo ‘ui’ guardados na respetiva pasta foram criados através da plataforma *Qt Designer*, que permite a criação de interfaces gráficas para *plugins* do QGIS. Estes ficheiros são depois consultados pelos ficheiros *Python* de forma a possibilitar, ao utilizador, a visualização das interfaces desenhadas.

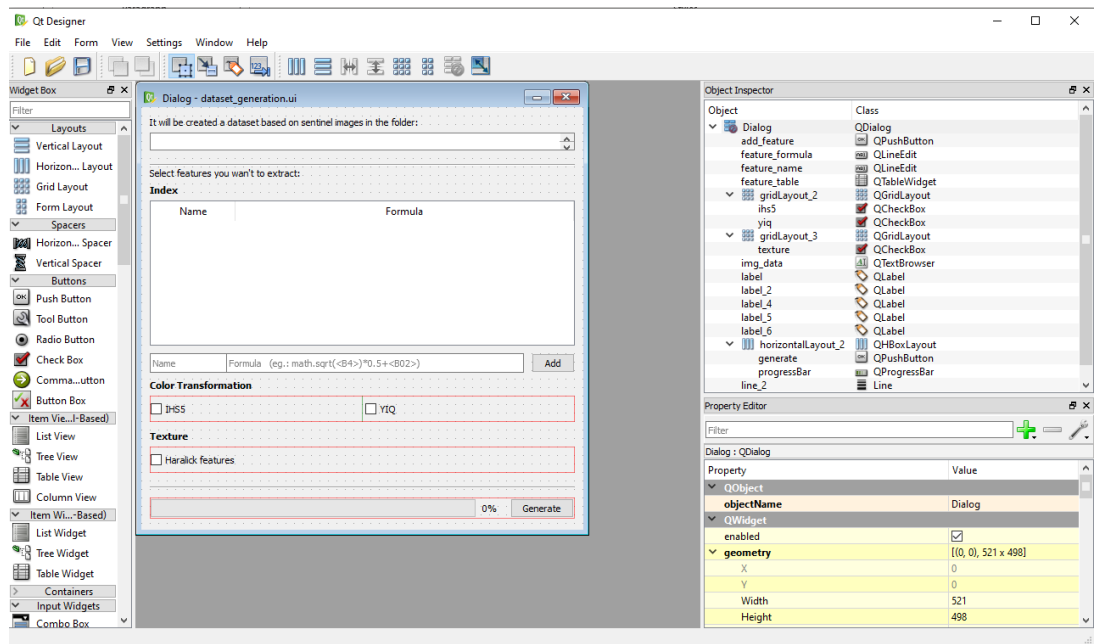


Figura 4.3 – Utilização do programa *Qt Designer* para desenvolvimento do ficheiro *dataset_generation.ui*

Segue-se uma breve descrição de cada um dos ficheiros criados, de notar que estes serão mencionados no capítulo correspondente ao ficheiro em que são utilizados.

- **Dataset_generation.ui** – Interface gráfica principal utilizada pelo ficheiro ‘create_workspace.py’;
- **Main.ui** – Interface gráfica principal utilizada pelo ficheiro ‘app.py’;
- **polyDialog.ui** – Interface gráfica utilizada no ficheiro ‘app.py’ quando é criado um novo polígono;

4.5 Resources

O ficheiro “resources.qrc” guarda a informação dos recursos utilizados nos ficheiros ‘ui’, ou seja, das imagens que são utilizadas para a produção dos mesmos no *Qt Designer*, mas que não fazem parte dos seus recursos.

Neste trabalho foram utilizadas as imagens da pasta ‘/ui/icons’ como recursos para criação da legenda das Classes. O menu dos recursos está acessível clicando nas propriedades de um *combobox* e em seguida nas reticências da opção *icon*.

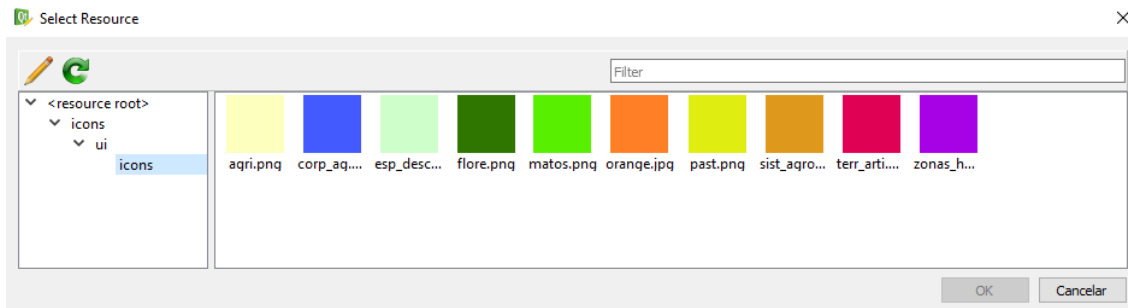


Figura 4.4 – Criação do recurso com os ícones de cada uma das Classes

As imagens foram criadas com o programa *Paint*, sendo que as cores escolhidas para as Classes foram retiradas de uma apresentação da DGT (Caetano, Marcelino, Igreja, & Girão, 2018).

Para ser possível a sua utilização em *Python*, o ficheiro foi compilado utilizando o comando:

```
pyrcc4 -py3 resource.qrc -o resource_rc.py
```

Este comando produziu o ficheiro “resource_rc.py” que é depois importando no ficheiro *Python*.

4.6 Estilo_cos

O ficheiro “estilo_cos.qml” foi criado através das propriedades de uma camada no QGIS, contém a informação das cores de cada uma das classes de acordo com o valor do atributo ‘Megaclassa’ contido em cada um dos polígonos da COS. Este é carregado pelo ficheiro “app.py” onde é possível visualizar o mapa da COS com as cores de cada Classe corretamente identificadas. Foi ainda criada uma outra versão deste ficheiro, o “estilo_cos_transparent.qml” que contém as mesmas cores e classes que o anterior, tendo 0% de transparência nos contornos do polígono e 30% no seu interior. Este ficheiro permite ao utilizador ver a imagem de satélite no interior do polígono, tendo também visível as suas fronteiras.

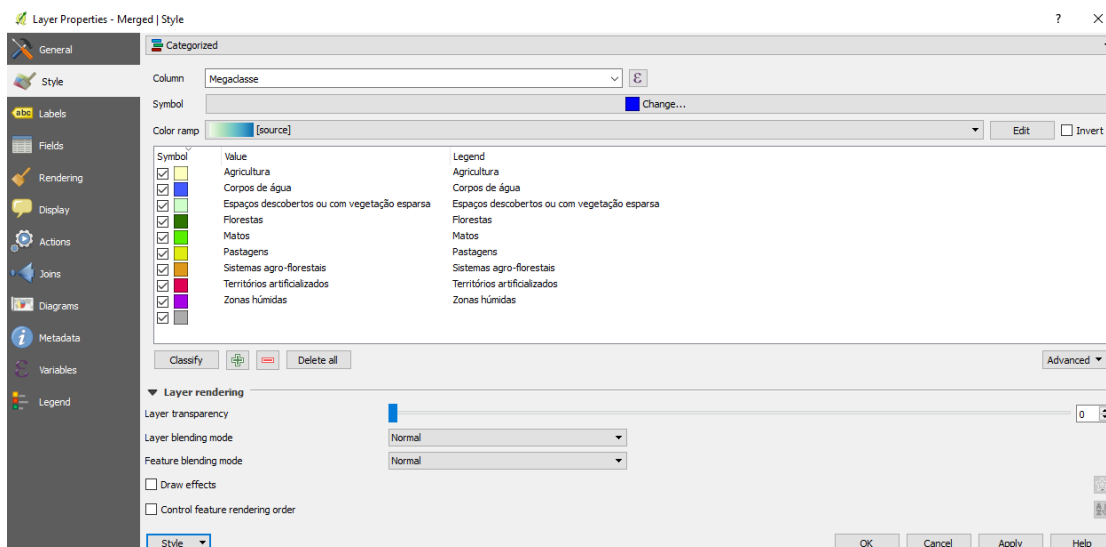


Figura 4.5 – Criação do ficheiro “estilo_cos.qml” no QGIS

4.7 Setup

O ficheiro “setup.bat” contém uma lista de comandos que serão executados na linha de comandos ‘OsGeo4W Shell’, antes da primeira utilização da aplicação. O objetivo do ficheiro é fazer a instalação das bibliotecas que são importadas pela aplicação e que não estão instaladas por definição nesta *Shell*. As bibliotecas ‘scikit-image’ e ‘joblib’ são descarregadas da base de dados do *pip*, enquanto que para a biblioteca ‘numpy’ é utilizado um ficheiro ‘.whl’, uma vez que foi preciso instalar uma versão específica do mesmo para o correto funcionamento da aplicação.

```
cd setup
pip install --user numpy-1.16.3+mkl-cp27-cp27m-win_amd64.whl
pip install --user scikit-image
pip install --user joblib
```

4.8 Launch

Este ficheiro é semelhante ao anterior e é necessário executá-lo sempre que o ‘OSGeo4W Shell’ é aberto. O ficheiro adiciona as diretorias das bibliotecas do QGIS às variáveis de ambiente do sistema, esta foi a única solução encontrada para correr o programa.

4.9 Create_workspace

O ficheiro “create_workspace.py” é um dos principais da aplicação, deve ser executado para criar o *workspace*, uma pasta onde estão guardados os ficheiros relativos a cada um dos projetos criados.

4.9.1 Criação do *workspace*

Quando executado, o programa começa por pedir ao utilizador uma diretoria para guardar o *workspace*. O utilizador deve criar uma nova pasta e seleccioná-la. De seguida, é pedido que selecione o ficheiro *True Color Image* (TCI) da imagem de satélite pretendida, este ficheiro está presente na pasta descarregada do *IPSentinel* em GRANULE/L2A_.../IMG_DATA/10m/.

São criadas várias sub-pastas dentro do *workspace* onde serão guardados os vários ficheiros produzidos pelo sistema (cos, dataset, raster, shapefiles). É ainda criado um ficheiro de texto (‘data.txt’) onde é guardado o caminho para a pasta ‘IMG_DATA’ onde se encontram todas as imagens extraídas pelo *Sentinel*, divididas em pastas de acordo com a sua resolução espacial (10m, 20m e 60m).

4.9.2 Dataset_Generation

Posteriormente, é aberta a janela “dataset_generation.ui” (figura 4.6), nela podem ser escolhidos os atributos que serão extraídos. Podem ser seleccionados os índices de vegetação presentes na tabela (NDVI, NDWI, SAVI e EVI) que servem como exemplos para outros que poderão ser adicionados. É possível acrescentar novos índices, colocando o nome e fórmulas nos respetivos espaços e clicando em ‘Add’. A fórmula terá de ser escrita com algumas regras, uma vez que será interpretada como um comando *Python*. Podem ser utilizadas todas as bandas do *Sentinel-2*, estas devem ser escritas na fórmula com o respetivo nome entre um sinal de menor e um sinal de maior. Se necessário, são suportadas operações matemáticas simples, como adições e multiplicações. É, ainda, possível utilizar as funções da biblioteca ‘math’ como ‘sqrt’, ‘exp’, ‘sin’, etc. bastando escrever ‘math.sqrt()’, ‘math.exp()’, ‘math.sin()’, etc.

Dialog

It will be created a dataset based on sentinel images in the folder:

C:/Users/jpvar/Desktop/Tese/sentinel/S2A_MSIL2A_20190224T112111_N0211_R037_T29SNC_20

Select features you want to extract:

Index

Name	Formula
<input type="checkbox"/> ndvi	$(\langle B08 \rangle - \langle B04 \rangle) / (\langle B08 \rangle + \langle B04 \rangle)$
<input type="checkbox"/> ndwi	$(\langle B03 \rangle - \langle B08 \rangle) / (\langle B03 \rangle + \langle B08 \rangle)$
<input type="checkbox"/> savi	$(1 + 0.5) * ((\langle B08 \rangle - \langle B04 \rangle) / (\langle B08 \rangle + \langle B04 \rangle + 0.5))$
<input type="checkbox"/> evi	$2.5 * (\langle B08 \rangle - \langle B04 \rangle) / (\langle B08 \rangle + 6 * \langle B04 \rangle - 7.5 * \langle B02 \rangle + 1)$

Name Formula (eg.: $\text{math.sqrt}(\langle B4 \rangle * 0.5 + \langle B02 \rangle)$) **Add**

Color Transformation

☐ IHS5 ☐ YIQ

Texture

☐ Haralick features

0% **Generate**

Figura 4.6 – Janela ‘dataset_generation.ui’

Podem, também, ser extraídas as imagens relativas ao *IHS5*, *YIQ* e atributos *Haralick*, que serão explicados durante este capítulo. Após todas as opções selecionadas, pode ser clicado o botão ‘generate’ e serão gerados todos os ficheiros que serão utilizados pela aplicação propriamente dita.

4.9.3 my_shapes

O “my_shapes” é um conjunto de ficheiros *shapefile* onde são guardados polígonos. Este é criado com o objetivo de guardar os polígonos desenhados na aplicação pelo utilizador ou selecionados diretamente dos polígonos da COS. O ficheiro é inicializado sem qualquer polígono e cada novo polígono terá os seguintes campos:

- **id** – identificador único para cada polígono;
- **megaclass** – nome da Megaclass associada ao polígono;
- **class_id** – identificador numérico da Megaclass, cada pixel terá o valor da sua Megaclass correspondente. A lista de cada Class_id e a sua respetiva Megaclass encontra-se na tabela 1;

Tabela 1 - Lista de Class_id e correspondente Megaclassa

Class_id	Megaclassa
1	Territórios Artificializados
2	Agricultura
3	Pastagens
4	Sistemas Agro-Florestais
5	Floresta
6	Matos
7	Espaços descobertos ou com vegetação esparsa
8	Zonas húmidas
9	Corpos de água

4.9.4 Cos_workspace

Este ficheiro, do tipo *shapefile*, é este ficheiro é utilizado pela aplicação para visualização da COS no mapa. O ficheiro contém apenas os polígonos da COS que fazem parte da área de estudo do respetivo *workspace*, ou seja, da área coberta pelas imagem do *Sentinel-2* selecionada. Deste modo não é necessário fazer o processamento de todos os polígonos contidos no ficheiro “cos_portugal”, diminuindo o tempo de processamento da aplicação e reduzindo a memória utilizada pelo mesmo.

Para a produção deste ficheiro começou-se por criar uma cópia do ficheiro “cos_portugal”, e em seguida foi utilizada uma função de interseção que permite verificar a interceção do retângulo correspondente à área da imagem do *Sentinel-2* com cada um dos polígonos da COS. Todos os polígonos fora desta interseção foram removidos. Após a delimitação da área de interesse, foi adicionado a cada um dos polígonos o atributo ‘class_id’, com o mesmo comportamento e objetivo do descrito no subcapítulo anterior.

Por fim, foi criada uma nova cópia do ficheiro “cos_workspace” com o nome “cos_layer_visible”, que contém apenas os polígonos selecionados na aplicação. Só estes últimos serão visíveis pelo utilizador, caso o utilizador realize uma nova seleção é criado um novo ficheiro “cos_layer_visible” na aplicação, sempre com base no ficheiro “cos_workspace” onde estão todos os polígonos da área de estudo. É ainda importante realçar que por vezes existem polígonos que têm uma grande área fora da zona de estudo, estes são apresentados uma vez que acabam por a intersectar.




Figura 4.7 - Imagem aérea sobreposta com os polígonos da COS que a intersectam

Na figura 4.7 este efeito é facilmente verificável, sendo possível ver uma área retangular central que corresponde à imagem aérea e nas extremidades aparecem zonas que se estendem bastante para zonas fora deste retângulo. Este efeito é muito visível na rede de estradas (rosa na figura 4.7) e nos rios (azul na figura 4.7).

4.9.5 Pasta dataset

Na pasta ‘dataset’ será guardado o *dataset* gerado sob a forma de imagens do tipo *.tiff*, cada imagem contém informações do respetivo atributo. Serão extraídos das imagens os seguintes atributos:

- Bandas 1, 2, 3, 4, 5, 6, 7, 8, 8A, 9, 11 e 12 do Sentinel-2;
- COS;
- Índices (apenas os selecionados pelo utilizador);
- Transformações IHS5 e YIQ (apenas os selecionados pelo utilizador);
- *Haralick Features* (se selecionado pelo utilizador);
- Class (gerado apenas na aplicação);
- Poly_id (gerado apenas na aplicação);

Cada uma das imagens contém uma resolução espacial de 10x10m por pixel, idêntica à imagem do Sentinel-2 de maior qualidade. Como tal, foi necessária a reamostragem das imagens aéreas de pior resolução para tirar o máximo partido da informação contida nestas imagens aumentando a precisão do classificador (Zheng, Du, & Chen, 2017). Segue-se uma descrição detalhada de como foram produzidos estes ficheiros.

4.9.5.1 Bandas do *Sentinel*

Para a geração das imagens do *dataset* relativas às bandas do *Sentinel*, é utilizada a função ‘gdal_translate’, que permite converter estas imagens em diferentes formatos, utilizando técnicas de redimensionamento ou reamostragem. Foi utilizado o comando:

```
'gdal_translate -of GTiff -ot Float32 -outsize 200% 200% -r bilinear 'B05.jp2' 'B05.tiff'
```

As imagens são disponibilizadas pelo programa *Copernicus*, no formato ‘.jp2’ e são transformadas em *GTiff*, ou seja, num ficheiro *.tiff* georreferenciado. Cada valor de pixel do ficheiro de saída é do tipo Int16, isto porque a resolução radiométrica deste tipo de bandas é de 10000. O valor de *outsize* é a razão entre a resolução da antiga imagem e a nova, é utilizado 100% para as bandas com resolução de 10m, uma vez que estas já se encontram com a resolução escolhida, 200% nas imagens com resolução de

20m e 600% nas de 60m. É utilizada a interpolação bilinear para cálculo dos novos valores dos pixéis na sua reamostragem.

4.9.5.2 Cos

O ficheiro “cos.tiff” contém informação relativa aos polígonos da COS 2015, o ficheiro foi criado com o objetivo de servir de validação para o modelo classificativo gerado utilizando o *dataset* produzido. É possível comparar os valores dos pixéis gerados pelo classificador com os valores da COS como forma de cálculo da precisão do modelo. É importante mencuinar que este método de avaliação não é completamente correto, uma vez que a COS usada foi produzida com a utilização de imagens aéreas de 2015 e o modelo estará a ser produzido com imagens mais recentes. É também importante ter em atenção que os mapas COS não estão 100% corretos, tal como indicado no subcapítulo 1.2.

Para a criação desta imagem começou por ser utilizada a função ‘gdal_rasterize’, que transforma ficheiros vetoriais em imagens raster.

```
'gdal_rasterize -a class_id -ot Int16 -of GTiff -tr 10 10 -l cos_workspace cos_workspace.shp class_aux.tiff'
```

Para este passo é utilizado o ficheiro “cos_workspace” onde estão guardados os polígonos que interseam com a zona de estudo. A imagem é criada com base no valor da ‘class_id’, o que significa que cada pixel da nova imagem terá o valor desse atributo, com o tipo de dados ‘Int16’. É também configurada a resolução da imagem resultante para 10m, tal como todas as imagens da pasta ‘dataset’. O ficheiro de saída é do tipo *.tiff*, no entanto ainda não é o ficheiro “cos.tiff” final. Este ficheiro apresenta toda a área abrangente dos polígonos da ‘cos_workspace’, mas esta área não corresponde à área da imagem do *Sentinel-2*, pelo que é necessário cortar a imagem com a função ‘gdalwarp’.

```
'gdalwarp -ot Int16 -s_srs EPSG:3763 -t_srs EPSG:32629 -r near -of GTiff -tr 10 10 -te x1 y1 x2 y2 class_aux.tiff cos.tiff'
```

Para efetuar o corte é necessária uma transformação do sistema de coordenadas, porque o ficheiro “cos_workspace.shp” usa um sistema de coordenadas (EPSG:3763) diferente das imagens geradas das bandas do *Sentinel-2* (EPSG:32629). É utilizada a técnica de reamostragem de vizinho mais próximo (*near*), uma vez que cada

valor é discreto e representa uma ‘Megaclass’, não podendo ser gerados valores distintos dos anteriormente existentes. É ainda selecionada a resolução da imagem resultante de 10m, assim como uma zona de corte da imagem (x_1 y_1 x_2 y_2) que representa as extremidades da imagem do *Sentinel-2*.

4.9.5.3 Índices e Transformações do esquema de cores

O cálculo dos índices e transformações do esquema de cores são realizados de forma semelhante. As bandas utilizadas para estes cálculos são transformadas em vetores ‘numpy’ que permitem o cálculo eficiente de dados multidimensionais, sendo também utilizada a biblioteca ‘math’ para funções como raiz quadrada.

É importante referir que os valores das bandas do *Sentinel* utilizadas nos índices presentes e adicionados pelo utilizador são sempre normalizadas através de uma divisão por 10000, o valor máximo que estas bandas podem tomar. Para o cálculo destes índices é utilizada a função do *Python* ‘eval’ que permite executar uma *string*, interpretando-a como uma linha de código. Esta função recebe a fórmula correspondente ao índice a calcular, que é a *string* apresentada na janela ‘dataset_generation.ui’, na tabela dos índices. No entanto, são substituídos os símbolos menor e maior (<B02>) pelo código que permite carregar a respetiva banda (numpy.array(Imagem.open(B02))).

4.9.5.4 Atributos *Haralick*

Os atributos *Haralick* permitem extrair da imagem informação relativa à sua textura, característica importante para a identificação de tipos de terreno. Numa fase inicial, é criada uma imagem em tons de cinzento, fazendo a média das bandas vermelho, verde e azul. Posteriormente, esta imagem é normalizada e discretizada de modo a que a gama valores de cinzento esteja de acordo com o número de níveis de cinzento escolhido. Este passo é fundamental, uma vez que é a partir deste número de valores possíveis que é criada a matriz de correlação.

Inicialmente esta normalização foi feita dividindo o valor de cinza pelo valor total da gama que estes valores podem tomar, isto é, a resolução radiométrica da imagem do nível 2A correspondente a 10.000; seguida de uma multiplicação por 15, uma vez que foram selecionados 16 níveis de cinzento, considerados suficientes na maioria dos casos em (Albregtsen, 2008). No entanto, praticamente não existem valores da imagem a cima dos 12 bits (4.092, correspondente à resolução radiométrica da imagem do nível

1C), o que após a normalização e discretização nos leva a uma variância dos novos valores da imagem muito baixa e não tomando proveito dos 16 níveis de cinza, este facto gera atributos de textura com uma variância quase nula, não adicionando qualquer informação ao *dataset*. A distribuição dos valores da 'energia', um dos atributos extraídos, encontra-se no histograma (a) da figura 4.8. É possível que existe uma grande concentração dos valores perto do valor 1, isto acontece devido à grande quantidade de pares (referência, vizinhos) idênticos, devido a essa mesma falta de variância.

Para tentar combater esta falta de variância, a normalização foi feita através da divisão por 4.092, seguida de uma multiplicação por 15, sendo que todos os valores inicialmente superiores a 4.092 foram considerados como tendo o nível máximo de cinza de 15. O histograma (b) tem representado o atributo 'energia' extraído. Apesar da melhoria significativa da distribuição destes valores, ainda existem muitas instâncias com o valor 1.

Numa tentativa de melhorar esta distribuição, a normalização foi feita para o valor máximo de 4.092, seguida de uma multiplicação por 63, sendo assim escolhido o valor de 64 níveis de cinzento. Este aumento do número de intervalos dá origem a uma maior variação dos pares (referência, vizinho), a custo de um maior tempo de computação. No entanto, os resultados obtidos melhoraram significativamente, como se pode constatar pela análise do histograma (c). Apesar de ainda existirem algumas ocorrências de valor 1, estas foram mais tarde identificados como pertencentes à Classe 'Corpos de Água' quase na sua maioria. O resultado desta abordagem é muito semelhante à utilização de uma normalização servindo-se do valor máximo de 10.000 com o número de níveis de cinzento de 128. No entanto, a utilização desta quantidade de níveis de cinzento aumenta significativamente o tempo de processamento e, uma vez que a imagem não apresenta praticamente nenhum pixel com valor superior a 4.092, ambos os resultados são muito semelhantes.

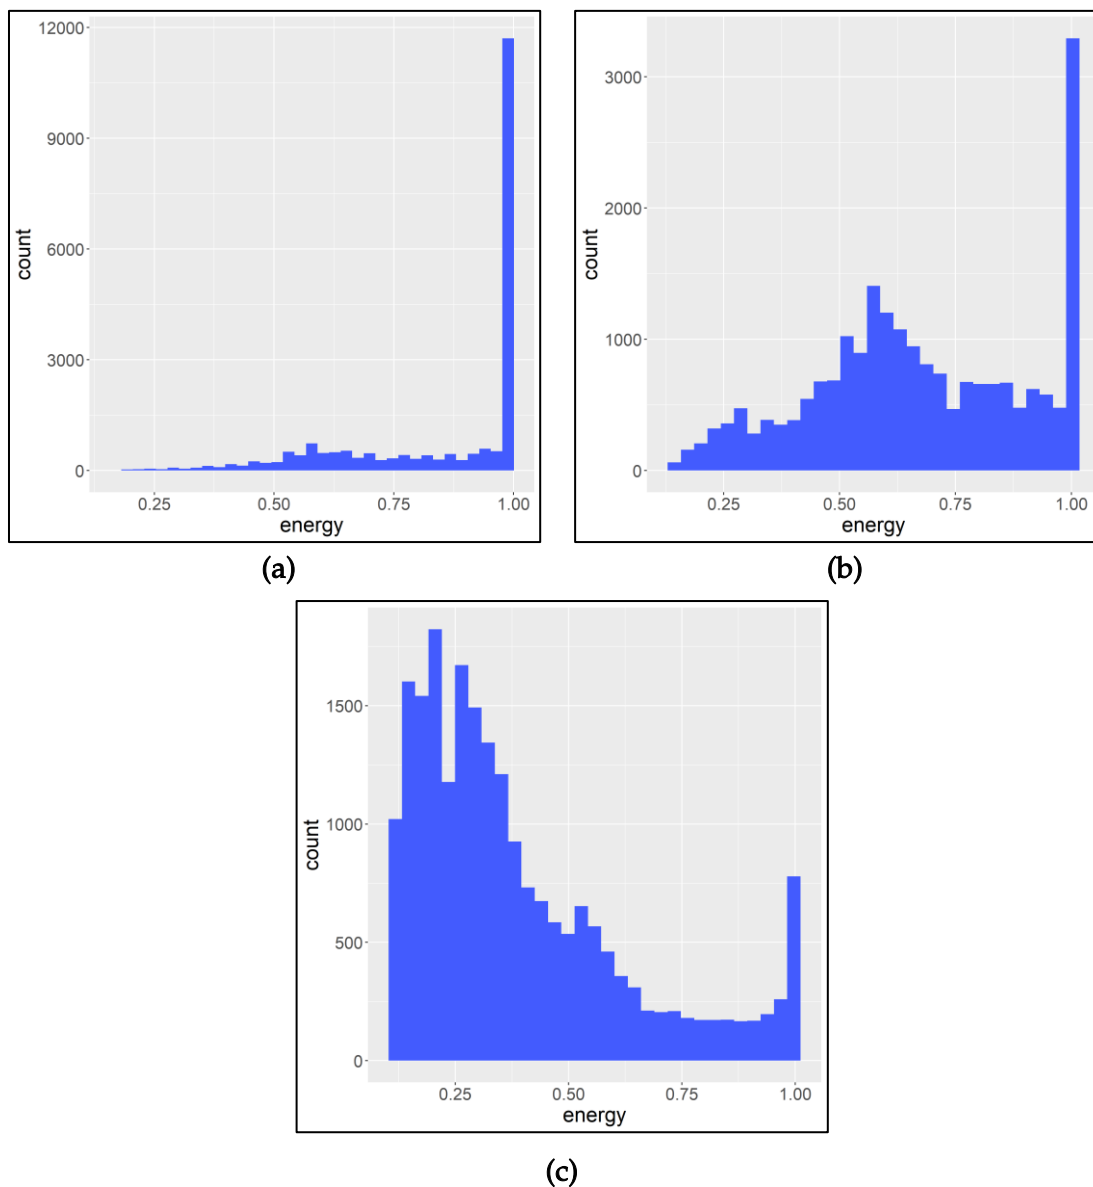


Figura 4.8 - Histogramas da distribuição dos valores extraídos do atributo 'energia'. Com normalização 10.000 e 16 níveis de cinza (a); Com normalização 4.092 e 16 níveis de cinza (b); Com normalização 4.092 e 64 níveis de cinza (a); Obtido através da plataforma R

A imagem em tons de cinza foi depois expandida, tendo sido adicionados três pixels nas suas bordas. Este passo é fundamental uma vez que a imagem será percorrida com uma janela deslizante, onde são consultados os valores dos pixels numa janela 7x7 centrada em cada um dos pixels da imagem, para efeitos de cálculos (Figura 4.9).




Figura 4.9 – Expansão da imagem. A azul está representa a imagem original, a azul escuro o pixel a ser calculado (utilizando o valor dos pixéis da área contida no retângulo com contorno preto mais definido), e a cinza os pixéis adicionados.

Uma vez que as imagens resultantes desta operação não são geradas numa só iteração, é necessária a criação de novas imagens, onde os valores dos cálculos vão sendo guardadas durante todo o processo. Deste modo, são criadas 6 imagens, inicializadas com o valor zero, cada uma das imagens corresponde a um atributo que será extraído: contraste, dissimilaridade, homogeneidade, segundo momento angular, energia e correlação.

Para reduzir o volume de informação a tratar de cada vez, a imagem foi dividida em 100 subconjuntos. O processamento foi assim dividido por 100, uma vez que este é um processo que ocupa muita memória, diminuindo assim significativamente a sua utilização de aproximadamente 6000MB para 1400MB. Com o auxílio da função 'range' do *Python* é criada uma lista (*chunk*) com os índices de cada um dos pixéis a ser processado, esta lista é o parâmetro de entrada para a função 'Parallel' da biblioteca 'joblib'.

O código *Python* desenvolvido corre apenas num *core* do processador do computador, não utilizando todo o seu poder de processamento. Os primeiros testes realizados para o cálculo das texturas demoraram vários dias para correr toda a imagem do *Sentinel*. A biblioteca 'joblib' facilita o processo de paralelização de código *Python*,

permitindo a utilização de vários *cores*, e assim diminuir o seu tempo de processamento. A função ‘Parallel’ é utilizada da seguinte forma:

```
ret = Parallel(n_jobs=-1, verbose=1)(delayed(glcm)(i, gray_level_img, row) for i in chunk)
```

Esta função funciona como um ciclo onde cada uma das iterações corre em *cores* distintos, a função faz a gestão de quantas iterações são enviadas para cada um dos *cores* maximizando a sua *performance*. O parâmetro de entrada ‘n_jobs’ é o número de *cores* a serem utilizados, com o valor -1 são utilizados todos os disponíveis na máquina. O ‘verbose’ é apenas o nível de detalhe apresentado na consola durante o correr do programa. No parâmetro ‘delayed()’ é definida a função que será chamada em cada uma das iterações, neste caso é a função ‘glcm()’ criada para o cálculo da matriz de correlação. Os parâmetros de entrada da função ‘glcm()’ são depois apresentados:

- **i** – índice do pixel a ser processado;
- **gray-level-img** – imagem do *Sentinel* transformada para tons de cinza;
- **row** – Número de linhas da imagem (utilizada para cálculo da posição do pixel através do índice);

É importante referir que o primeiro parâmetro da função chamada dentro do ‘delayed()’ é a variável que é iterada durante estes ciclos. Neste caso é a variável ‘i’ e que terá os valores de todos os índices da lista de índices (*chunk*), iterativamente.

Depois de todas as iterações completas, a função ‘Parallel’ devolve uma lista de todos os valores retornados pela função ‘glcm()’. Esta lista será depois processada com vista a passar os resultados para cada uma das imagens anteriormente criadas. No final de todo o processo estas imagens são guardadas na pasta ‘dataset’.

Na figura 4.10 está representado um esquema do todo o processo explicado anteriormente.

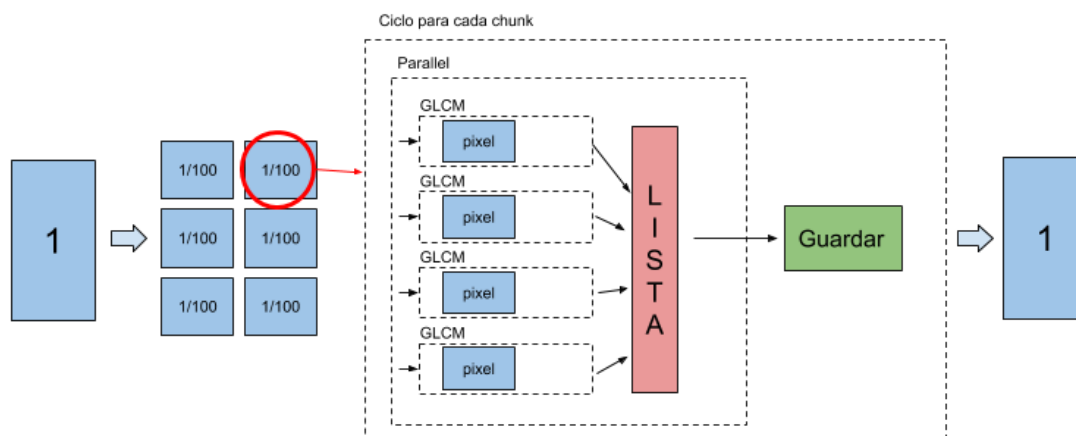


Figura 4.10 – Diagrama do método para o cálculo das imagens da textura (a azul está representado o nível de detalhe da imagem; a vermelho a lista; a verde o processo de guardar os valores na respetiva imagem; e a tracejado cada uma das funções ou ciclos usados)

A função 'glcm()' é onde os cálculos dos valores dos atributos das texturas são calculados. Começa por ser criada uma janela 7x7 centrada no pixel a ser processado. De seguida é chamada a função 'greycomatrix' da biblioteca 'skimage', que permite o cálculo da GLCM para esta janela 7x7. Para esta última função são definidos os seguintes argumentos:

- ***Distances*** – lista das distâncias entre dois pixéis para cálculo da GLCM, neste caso apenas é utilizado a distância de 1;
- ***Angles*** – lista do ângulos com as direções a percorrer para fazer os pares de pixéis para cálculo da GLCM, são utilizados os valores de 0°, 45°, 90° e 135°.
- ***Levels*** – Número de níveis é igual a 64, uma vez que este é o número de possíveis valores distintos de intensidade;
- ***Normed*** – Configurada para *True*, a matriz produzida é normalizada, isto porque é necessária a sua normalização para cálculo dos atributos *Haralick*;
- ***Symmetric*** – Configurada para *True*, a matriz produzida é simétrica. Quando a matriz está a ser criada e é encontrado o par (1-3) por exemplo, é incrementada uma unidade na matriz não só na posição (1,3) como também na (3,1). É esta propriedade que permite utilizarmos apenas os ângulos 0°, 45°, 90° e 135°, uma vez que as direções contrárias (180°, 225°, 270°, 315°)

são representadas na matriz quando é incrementada a posição com linha e o coluna trocadas. O cálculo desta matriz é assim tornado mais rápido.

A matriz de correlação obtida é depois utilizada pela função 'greycopros', que recebendo a matriz e o identificador do atributo a ser calculado, retorna uma lista de quatro resultados, um para cada um dos ângulos escolhidos. Dos quatros ângulos é feita uma média, sendo o valor final do pixel de cada atributo. A função 'glcm()' tem como retorno um vetor, onde se encontram a posição x e y de um pixel na imagem, seguida de 6 valores, cada um com o valor dos atributos calculados. A lista formada no final da função 'parallel' é uma lista de vetores deste tipo.

4.9.6 Ficheiros *Raster*

Os ficheiros *raster* são guardados dentro da pasta 'raster', e permitem vários modos de visualização no mapa da aplicação desenvolvida, estes são produzidos através do comando *gdal_merge*:

```
'gdal_merge -separate -o /raster/Cor_Natural.tiff -ot Float32 -of GTiff red green blue'
```

Este comando permite a junção de várias imagens numa outra imagem com várias camadas, neste caso são juntas as camadas vermelho, verde e azul para o ficheiro "Cor_Natural.tiff". A opção 'separate' é utilizada para colocar cada uma das camadas numa camada diferente da imagem *output*. Foram gerados os modos de visualização presentes na tabela 3, sendo que cada um dos modos facilita a identificação de tipos de terreno distintos.

Tabela 2 - Lista do Modos de Visualização com as respectivas bandas utilizadas para as componentes RGB. Retirado de <https://acolita.com/lista-de-combinaciones-de-bandas-en-sentinel-2a/>

Lista de Modos	R	G	B
Agricultura	B11	B08	B02
Análise de vegetação	B11	B08	B04
Cor Natural	B04	B03	B02
Cor Natural (s/ atmosfera)	B12	B08	B03
Falsa Cor Infravermelho	B08	B04	B03
Falsa Cor Urbano	B12	B11	B04
Infravermelho Onda Curta	B12	B08	B04
Profundidade Atmosférica	B12	B11	B8A
Terra / Água	B08	B11	B04
Vegetação Saudável	B08	B11	B02

4.9.7 Organização dos ficheiros gerados

No final do processamento de todo o programa, a pasta do *workspace* gerada contém os ficheiros apresentados na figura 4.11. De notar que não se encontram representados os ficheiros *.tiff* gerados, guardados na pasta 'dataset', estes serão apresentados no capítulo seguinte.

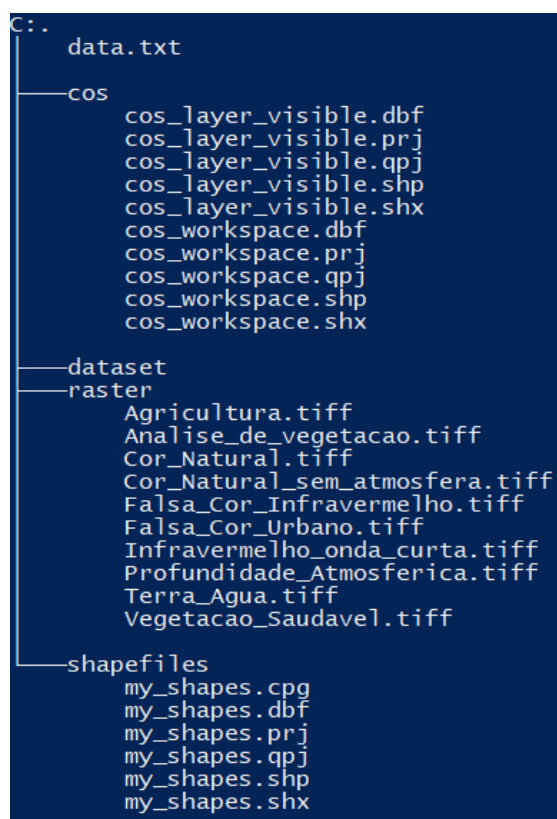


Figura 4.11 - Esquema em árvore da distribuição dos ficheiros de um novo workspace (não apresentados os ficheiros *.tiff* na pasta 'dataset')

4.10 App

Este ficheiro é um ficheiro *Python* onde se encontra a interface principal, sobre a qual o utilizador pode desenhar os polígonos que vão dar origem ao *dataset* final. Na figura 4.12 está a representada a interface desenvolvida.

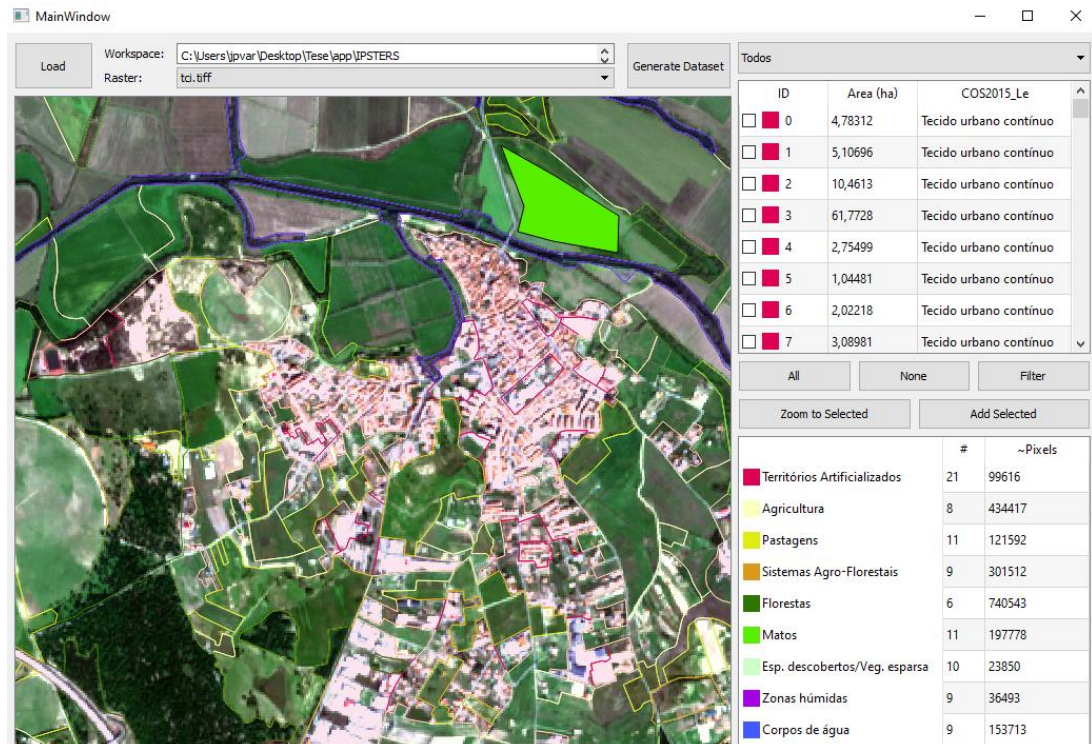


Figura 4.12 - Interface gráfica da aplicação

Segue-se uma descrição de cada um dos componentes da aplicação.

4.10.1 Load

Ao clicar no botão *'load'* é aberta uma janela onde o utilizador deve seleccionar a pasta de um *workspace*, este foi previamente criado com o ficheiro *Python 'create_workspace'*.

4.10.2 Workspace e Raster

Do lado direito do botão *'load'* é possível visualizar dois elementos da interface, o *'workspace'* onde está descrito o caminho para o *workspace* aberto, e o *'raster'*. A opção *'raster'* permite escolher o modo de visualização da imagem aérea no mapa. Podem ser seleccionadas as dez opções referidas na tabela 3, um exemplo destes modos de visualização encontra-se na figura 4.13.



(a)



(b)



(c)



(d)




(e)



(f)



(g)



(h)



(i)



(j)

Figura 4.13 - Exemplos de imagens dos vários modos de visualização da aplicação. Agricultura (a), Análise de Vegetação (b), Cor Natural (c), Cor Natural (sem atmosfera) (d), Falsa Cor Infravermelho (e), Falsa Cor Urbano (f), Infravermelho Onda Curta (g), Profundidade Atmosférica (h), Terra / Água (i), Vegetação Saudável (j).

O modo 'Cor Natural' permite ver a imagem aérea de uma forma idêntica ao que a vemos com os nossos olhos, ajudando na identificação de vários elementos. A imagem 'Falsa Cor Infravermelho' realça a vermelho as zonas de vegetação, sendo que as zonas artificializadas ficam com uma cor mais clara.

4.10.3 Canvas

Canvas é o nome que se dá à área de desenho, onde se encontra a imagem aérea do *Sentinel*. O *canvas* permite a visualização de 3 camadas distintas:

- **Imagem aérea** – Esta imagem é a última camada que podemos visualizar, a imagem aérea que pode ser vista os dez modos descritos em cima. O utilizador dispõe destas imagens como apoio para o desenho dos seus polígonos;
- **COS 2015** – Na figura 4.12 podemos ver os polígonos da COS 2015, sendo a sua fronteira representada pela cor correspondente à respetiva Megaclassa de acordo com a legenda (no canto inferior direito da mesma figura). O utilizador tem estes polígonos como referência para os desenhos dos seus polígonos;
- **My_shape** – Este ficheiro foi criado no “create_workspace” ainda sem qualquer polígono, o seu objetivo é guardar os polígonos desenhados pelo utilizador ou adicionados diretamente dos polígonos da COS. Os polígonos da COS 2015 encontram-se desatualizados de acordo com as imagens de satélite que poderão estar a ser utilizadas no *workspace*. Para que seja produzido um bom *dataset*, é necessária a correta amostragem de pixéis de cada uma das Megaclasses. Assim sendo, o papel do utilizador é, utilizando as restantes camadas do *canvas*, selecionar polígonos representativos de cada uma das classes, que contenham apenas pixéis dessa mesma classe. Estes polígonos podem ser desenhados clicando com o botão esquerdo do rato no *canvas*, marcando cada um dos pontos que definiram esse novo polígono, e finalizando com um clique do lado direito surgindo uma janela onde é escolhida a megaclassa pretendida. O processo de desenho destes polígonos encontra-se representado na figura 4.14.




Figura 4.14 - Processo de desenho de um novo polígono (canto superior esquerdo: podemos identificar uma zona com contorno amarelo, ou seja zona de pastagens; canto superior direito: é desenhado o polígono (a vermelho); canto inferior esquerdo: é escolhida a Megaclassa 'Pastagens'; canto inferior direito: novo polígono desenhado preenchido a amarelo)

4.10.4 Lista de polígonos

No canto superior direito da aplicação encontra-se a lista dos polígonos da COS. Nesta lista estão representados todos os polígonos que foram adicionados ao ficheiro “cos_workspace” criado através do ficheiro “create_workspace”, ou seja, todos os polígonos da COS que interseitam a nossa área de estudo. Cada um dos elementos da lista contém um identificador único para cada polígono com um ícone referente à Megaclassa do mesmo, a sua área em hectares e a descrição do nível mais detalhado da

COS (COS2015_Le). Esta lista pode ser ordenada por ordem crescente e decrescente de cada uma das colunas, através do clique no respetivo cabeçalho.












Todos			
	ID	Area (ha)	COS2015_Le
<input type="checkbox"/>	 7305	12255,7	Florestas de sobreiro
<input type="checkbox"/>	 47862	10528,3	Sistemas agro-florestais ...
<input type="checkbox"/>	 90300	10438,3	Florestas de pinheiro bra...
<input type="checkbox"/>	 39948	9566,4	Florestas de pinheiro bra...
<input type="checkbox"/>	 19317	8062,11	Florestas de sobreiro
<input type="checkbox"/>	 5045	8022,47	Florestas de pinheiro bra...
<input type="checkbox"/>	 84825	7441,17	Desembocaduras fluviais
<input type="checkbox"/>	 56519	7173,12	Culturas temporárias de ...
<input type="checkbox"/>	 7192	6190,82	Florestas de sobreiro
<input type="checkbox"/>	 39926	5620,15	Florestas de pinheiro bra...
<input type="checkbox"/>	 66422	5583,92	Florestas de sobreiro
All None Filter			
Zoom to Selected		Add Selected	

Figura 4.15 - Lista dos polígonos da COS com o respetivo ID, área (em há) e nível mais detalhado da COS

Por cima da lista encontra-se um *combobox*, onde é possível selecionar por Megaclassa dos polígonos presentes nesta lista. Na primeira coluna da tabela temos um *checkbox* para cada um dos elementos da lista, é possível ao utilizador selecionar quais os polígonos da COS visíveis no *canvas*, sendo necessário o clique no botão 'Filter' para a sua atualização. Os botões 'All' e 'None' servem de atalho para selecionar todas ou nenhuma das *combobox* dos polígonos, respetivamente. A camada visível ao utilizador no *canvas* com os polígonos da COS é proveniente do ficheiro "cos_layer_visible", sendo este atualizado sempre que é clicado o botão 'Filter'.

É ainda possível utilizar os botões 'Zoom to Selected' e 'Add Selected' selecionando primeiro um dos elementos da lista. O 'Zoom to Selected' faz com que seja exibida no *canvas* a área respetiva ao polígono selecionado. O segundo permite adicionar o polígono selecionado diretamente à lista de polígonos desenhados pelo utilizador, esta operação pode ser útil em casos que os polígonos da COS ainda estejam atualizados, estes casos são mais comuns em áreas artificializadas, uma vez que estas não so-

frem tantas alterações ao longo dos anos, como é o caso das fronteiras das florestas, matos ou corpos de água.

4.10.5 Legenda

A tabela localizada no canto inferior direito serve de legenda para facilitar a identificação dos polígonos da COS e dos polígonos desenhados pelo utilizador no *canvas*. Na tabela encontra-se ainda uma coluna ‘#’ referente ao número de polígonos de cada classe desenhados pelo utilizador. A coluna ‘~Pixels’ contém uma aproximação de quantos pixéis estão representados nos polígonos desenhados. Esta última coluna serve como auxílio ao utilizador para a do *dataset*, uma vez que para a criação de um bom *dataset* é fundamental o equilíbrio entre o número de elementos em cada classe. Quando estes valores estiverem de acordo com os requisitos do utilizador o *dataset* estará pronto para ser finalizado.

	#	~Pixels
 Territórios Artificializados	21	99616
 Agricultura	8	434417
 Pastagens	12	122686
 Sistemas Agro-Florestais	9	301512
 Florestas	6	740543
 Matos	11	197778
 Esp. descobertos/Veg. esparsa	10	23850
 Zonas húmidas	9	36493
 Corpos de água	9	153713

Figura 4.16 - Legenda do mapa com respetivo número de polígonos desenhados e aproximação de quantidade de pixéis representados

4.10.6 Generate Dataset

O botão ‘generate_dataset’ é clicado quando o *dataset* estiver pronto para ser finalizado, são posteriormente criados os ficheiros “class.tiff” e “poly_id.tiff”.

Ambos os ficheiros são criados de uma forma muito semelhante ao ficheiro “cos.tiff”, explicado no capítulo anterior, onde são utilizadas as funções ‘gdal_rasterize’ e ‘gdalwarp’. O ficheiro “class.tiff” é criado rasterizando a campo ‘class_id’ onde se encontra o identificador da Megaclasse do polígono, este ficheiro

vem transformar os polígonos desenhados pelo utilizador numa imagem onde cada um dos pixéis é etiquetado. São estes valores dos pixéis que servem como a classe dos pixéis previamente classificados, utilizados para construção de modelos *machine learning* supervisionados. Uma vez que nem todos os pixéis da imagem criada estão contidos nos polígonos desenhados é necessário identificar os polígonos sem classe, foi utilizado o valor zero para esse fim, estes pixéis devem ser ignorados na fase de construção de um modelo classificativo.

Por sua vez, o ficheiro “poly_id.tiff” utiliza o campo ‘id’, sendo criada uma imagem onde cada pixel tem representado o valor do identificador único de cada um dos polígonos desenhados, este ficheiro não deve ser utilizado para construção do modelo, servindo apenas para a construção do ficheiro “dataset.csv”.

Por fim, é criado o ficheiro “dataset.csv”, este ficheiro contém informações de todas as imagens extraídas da imagem aérea, nomeadamente, as bandas, índices, transformações de espaço de cores e texturas. O objetivo do mesmo é a criação de uma tabela que vem resumir a informação contida em todas as outras imagens, podendo esta tabela ser utilizada para efeitos de classificação baseados em objetos. Este ficheiro, pode também ser utilizado para confirmar os valores obtidos nas imagens geradas. Em cada uma das linhas da tabela é representado um polígono dos desenhados pelo utilizador, a cada um desses polígonos é associado o valor de várias colunas:

- **Id** – identificador único para cada polígono;
- **N** – Número de pixéis contidos no polígono;
- **Class** – Identificador numérico da classe de acordo com a tabela 2;
- **Min, Max, Avg, Std** – Para cada uma das imagens do *dataset*, são calculados os valores mínimo, máximo, médio e desvio padrão para o conjunto de pixéis de cada polígono;

Na figura 4.17 encontra-se um exemplo deste ficheiro.

# id	N	class	asm(min)	asm(max)	asm(avg)	asm(std)	B01(min)	B01(max)	B01(avg)	B01(std)	B02(min)
1.00	508.00	1.00	0.11	0.75	0.25	0.11	511.23	1348.01	851.05	219.40	314.00
2.00	1051.00	1.00	0.06	0.84	0.25	0.11	453.41	1142.38	806.66	149.72	217.00
3.00	6162.00	1.00	0.05	0.88	0.21	0.10	223.92	1592.18	754.72	164.96	91.00
4.00	204.00	1.00	0.18	0.86	0.45	0.18	796.06	1831.69	1092.96	235.32	248.00
5.00	323.00	1.00	0.09	0.76	0.30	0.13	354.02	1674.37	653.72	235.77	209.00
6.00	412.00	1.00	0.08	0.96	0.25	0.12	283.89	1535.00	688.11	256.12	221.00
7.00	6288.00	1.00	0.07	1.00	0.33	0.23	113.72	1972.53	640.48	370.63	62.00
8.00	6219.00	1.00	0.05	1.00	0.29	0.13	183.97	1153.52	479.36	131.73	91.00
9.00	6244.00	1.00	0.03	0.96	0.23	0.13	311.91	2797.33	1176.85	385.78	143.00
10.00	6161.00	1.00	0.03	1.00	0.30	0.13	244.25	1400.73	659.12	135.65	79.00

Figura 4.17 - Exemplo de ficheiro 'dataset.csv'

4.10.7 *Dataset* final

Após gerado o ficheiro “dataset.csv”, o *dataset* encontra-se finalizado e disponível para utilização na pasta ‘dataset’ dentro do *workspace*, esta pasta contém os ficheiros indicados na figura 4.18.

```
C:\.
└── dataset
    ├── asm.tiff
    ├── B01.tiff
    ├── B02.tiff
    ├── B03.tiff
    ├── B04.tiff
    ├── B05.tiff
    ├── B06.tiff
    ├── B07.tiff
    ├── B08.tiff
    ├── B09.tiff
    ├── B11.tiff
    ├── B12.tiff
    ├── B8A.tiff
    ├── class.tiff
    ├── contrast.tiff
    ├── correlation.tiff
    ├── cos.tiff
    ├── dataset.csv
    ├── dissimilarity.tiff
    ├── energy.tiff
    ├── evi.tiff
    ├── homogeneity.tiff
    ├── ihs5_h.tiff
    ├── ihs5_i.tiff
    ├── ihs5_s.tiff
    ├── ndvi.tiff
    ├── ndwi.tiff
    ├── poly_id.tiff
    ├── savi.tiff
    ├── yiq_i.tiff
    ├── yiq_q.tiff
    └── yiq_y.tiff
```

Figura 4.18 - Esquema em árvore dos ficheiros presentes na pasta 'dataset'

Este *dataset* pode ser aproveitado para classificação baseado em pixel, através da utilização dos ficheiros *.tiff* onde cada uma das imagens corresponde a um atributo para a classificação, sendo que o ficheiro “class.tiff” é onde se encontra o atributo a

classificar. É importante reforçar que os ficheiros “poly_id.tiff” e “cos.tiff” não devem ser utilizados como atributos na construção do modelo. Estes últimos podem sim servir de fonte de auxílio para validação de resultados, apesar desta abordagem não ser a mais correta. O ficheiro “poly_id.tiff” pode ser utilizado para fazer algum tipo de outra análise relativamente aos polígonos, uma vez que é a única forma de saber qual o grupo de pixéis da imagem que pertencem ao mesmo polígono, sem recorrer a algoritmos de agregação, por exemplo. É ainda possível a construção de um modelo de classificação baseado no objeto, utilizando o ficheiro “dataset.csv”.

5 Apresentação e Discussão de Resultados

Como forma de validação dos resultados deste trabalho, foram extraídos os atributos referentes a uma imagem da zona de Mação (zona de estudo pelo projeto IPSTERS). Em seguida, foram desenhados manualmente alguns polígonos com a utilização da aplicação desenvolvida, criado e analisado um *dataset*, servindo este estudo como prova de conceito do trabalho proposto.

5.1 Dados

Para a criação do *dataset* foram descarregados os dados referentes às bandas do *Sentinel-2* da zona marcada a verde na figura 5.1, nomeadamente a região de Mação, que faz parte da área de estudo do projeto IPSTERS. Esta região intersesta quatro imagens do *Sentinel-2*, tendo sido escolhida a imagem que inclui Mação no canto superior direito. Esta escolha teve em conta a zona com maior área de superfície terrestre portuguesa e que não contém áreas espanholas ou zonas marítimas (ambas não classificadas pela COS).

A data da imagem, 24 de fevereiro de 2019, foi escolhida de forma a tentar minimizar a quantidade de nuvens, tendo uma percentagem de cobertura de nuvens de 0,18706. A imagem representa uma zona de aproximadamente 100x100km², com resoluções de 10m (bandas 2, 3, 4 e 8), 20m (bandas 5, 6, 7, 8, 8A, 11 e 12) e 60m (bandas 1 e 9).



Figura 5.1 – Mapa com zona da imagem de *Sentinel-2* descarregada para este caso de estudo (marcada a verde). Retirado de <https://ipsentinel.ipma.pt/dhus/#/home>

5.2 Extração dos atributos

As várias bandas descarregadas foram utilizadas para a extração dos atributos de toda a imagem, no entanto, para efeitos representativos, foi cortada uma zona de modo a facilitar a sua visualização (representada a vermelho na figura 5.1). Na figura 5.2 encontra-se a imagem de “Cor Natural” desta zona de corte, sendo possível identificar áreas de terreno artificializado, floresta, curso de água e terrenos agrícolas ou pastagens.



Figura 5.2 - Representação da imagem "Cor_Natural"

A presença destes tipos de ocupação de solo pode ser verificada através da figura 5.3, onde está representada a Carta de Ocupação do Solo de 2015 desta zona.




Figura 5.3 - Representação da imagem "cos", referente à Carta de Ocupação de Solo 2015. (1. Terrenos Artificializados; 2. Agricultura; 3. Pastagens; 4. Sistemas Agro-Florestais; 5. Floresta; 6. Matos; 7. Espaços descobertos ou com vegetação esparsa; 8. Zonas húmidas; 9. Corpos de água)

Analisando visualmente as imagens de alguns dos atributos extraídos, podemos identificar comportamentos interessantes que serão importantes para a construção do classificador. Observando o atributo “ndvi”, na figura 5.4, verificamos a existência de uma zona com maior índice no canto superior direito da imagem, onde o terreno é identificado na COS como floresta, na área de habitações este índice é neutro e em algumas das zonas de água o valor é negativo.

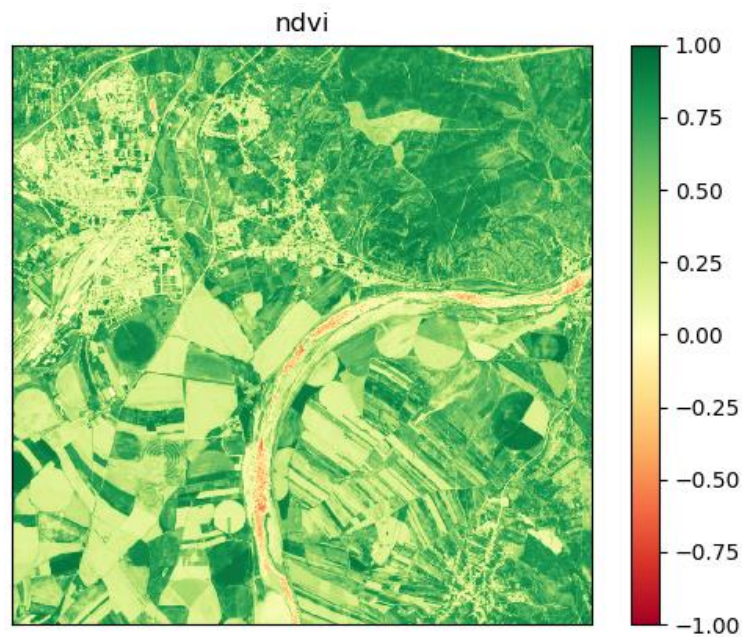


Figura 5.4 - Imagem do atributo "ndvi"

A imagem do “ndwi” da figura 5.5, realça bastante as zonas com presença de água, algumas delas dificilmente identificáveis na imagem de “Cor Natural”. É ainda possível observar que as zonas verdes apresentam valores mais baixos e as zonas artificializadas valores neutros.

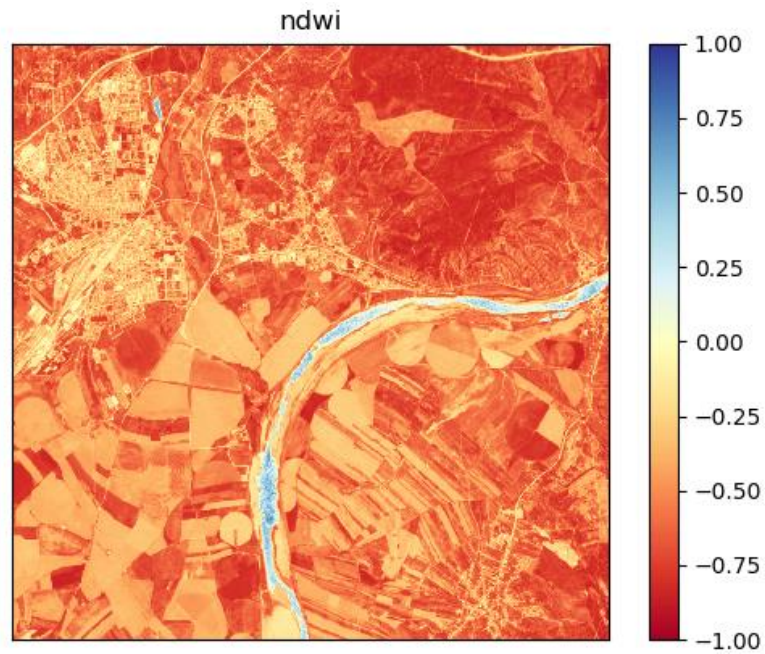


Figura 5.5 - Imagem do atributo "ndwi"

Na imagem da banda 7 da figura 5.6, são facilmente identificadas as zonas de água, com uma cor azul mais escura, enquanto que algumas das zonas de agricultura e pastagens encontram-se a amarelo.




Figura 5.6 - Imagem do atributo "B07"

Na figura verifica-se um grande contraste nas zonas artificializadas, devido à grande variação de cores dos elementos que os constituem como telhados, estradas ou passeios. Por outro lado, não é fácil de identificar as restantes Classes, sendo apenas verificado um grande contraste nas zonas de mudança de terreno, no tipo de terreno agrícola, por exemplo.




Figura 5.7 - Imagem do atributo "contrast"

Uma lista de todas as imagens dos atributos extraídos encontra-se em anexo.

5.3 Dataset

Foi utilizada a aplicação para o desenho manual de polígonos representativos de cada uma das classes. O ficheiro "class.tiff" foi gerado através destes polígonos e os pixéis gerados foram considerados as instâncias do *dataset*. A tabela 4 contém a quantidade pixéis e polígonos retirados, sendo que foi tido em consideração que o número de pixéis de cada Classe deve ser da mesma ordem de grandeza.

Tabela 3 - Número de polígonos e pixéis retirados da cada uma das Classes

ID	Classe	Nº de Polígonos	Nº de Pixéis
1	Territórios Artificializados	27	2084
2	Agricultura	21	2552
3	Pastagens	29	2537
4	Sistemas Agro-Florestais	12	2319
5	Floresta	33	2490
6	Matos	8	3047
7	Espaços descobertos ou com vegetação esparsa	11	2066
8	Zonas húmidas	13	2382
9	Corpos de água	20	2100

Através destes polígonos e da imagem aérea do *Sentinel-2* foi gerado o *dataset*, a distribuição dos valores dos atributos para cada uma das Classes está representada sob a forma de histogramas, uma lista dos histogramas de todos os atributos encontra-se em anexo.

A figura 5.8 contém alguns exemplos destes histogramas. Estudando a distribuição dos valores do atributo “energia”, verifica-se que os valores para a Classe “Corpos da água” são muito altos, isto porque estas zonas apresentam uma maior estabilidade. Por outro lado, as áreas artificializadas têm uma disposição mais irregular, originando valores de energia mais reduzidos. Na banda 5 é também possível distinguir com alguma facilidade as instâncias das Classes “Corpos de Água” e “Terrenos Artificializados” e é ainda possível identificar que os valores desta banda são também mais elevados para pixéis da Classe “Espaços descobertos ou com vegetação esparsa”.

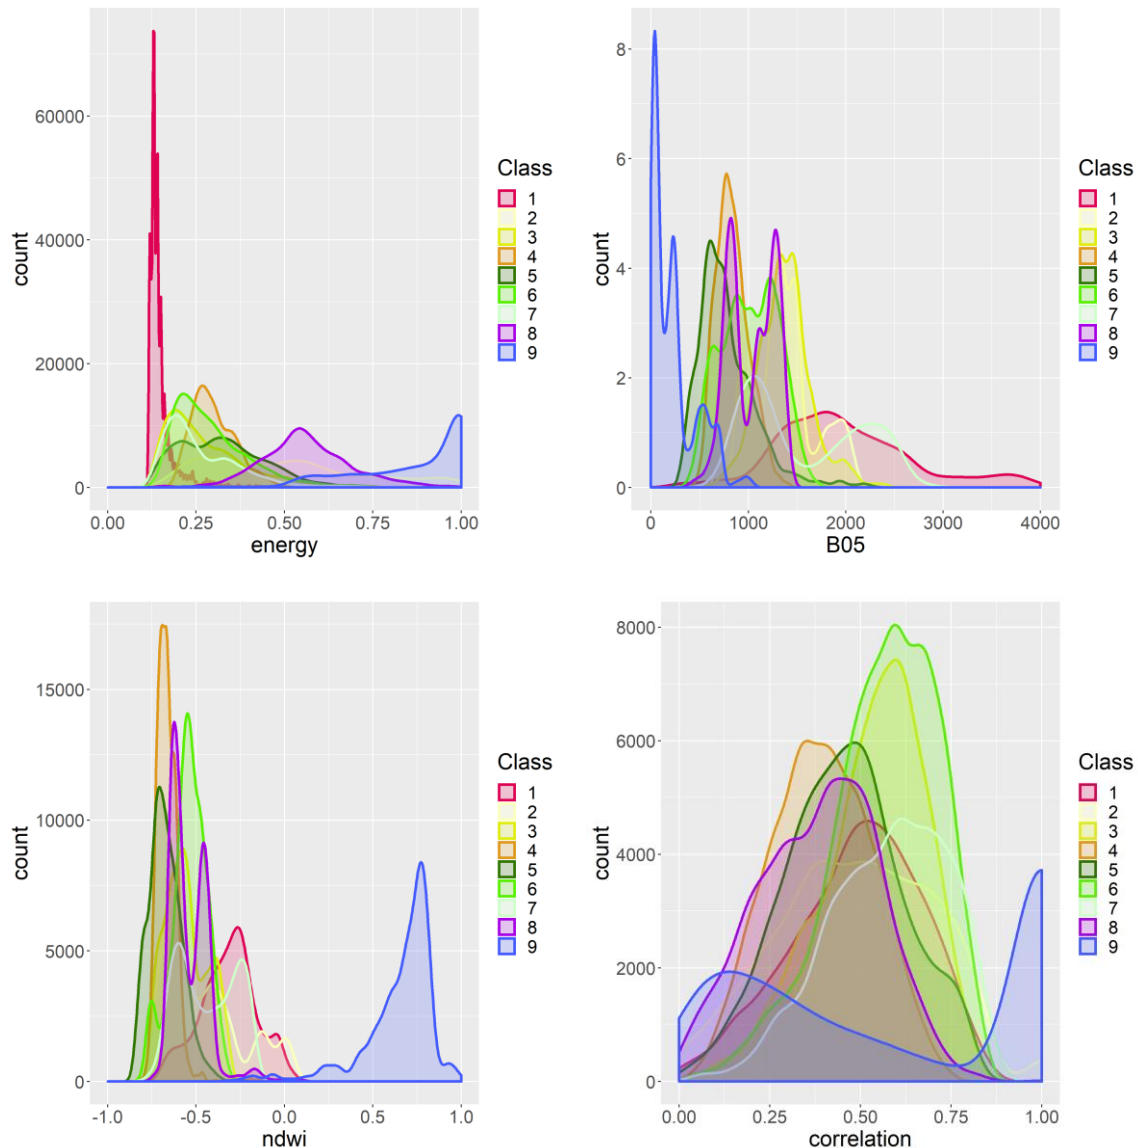


Figura 5.8 – Histogramas da distribuição dos valores dos atributos para cada uma das Classes dos atributos “energia”, “B07”, “ndwi” e “correlação” (1. Terrenos Artificializados; 2. Agricultura; 3. Pastagens; 4. Sistemas Agro-Florestais; 5. Floresta; 6. Matos; 7. Espaços descobertos ou com vegetação esparsa; 8. Zonas húmidas; 9. Corpos de água)

Como já considerado anteriormente, o atributo “ndwi” mostrou ser um bom identificador de “Corpos de água” e que os valores mais baixos deste índice representam zonas de “Floresta”. O histograma da correlação é um exemplo de distribuição de um atributo pouco discriminativo, onde o valor médio e variância de cada um dos atributos é muito semelhante.

Em todos os histogramas verifica-se uma grande semelhança na distribuição dos valores das Classes “Floresta”, “Matos”, “Agricultura”, “Sistemas Agro-Florestais” e “Pastagens”. Este comportamento era espetável, uma vez que todos estes terrenos apresentam características semelhantes. Por outro lado, zonas de “água” e “artificializadas” são identificadas mais facilmente. Este fenómeno será facilmente verificado aquando a classificação através da análise da matriz de confusão.

5.3.1 Avaliação dos atributos

De forma a avaliar a qualidade dos atributos do *dataset* foi utilizado o método da avaliação dos atributos com base na sua correlação de Pearson para cada uma das Classes. Os resultados desta análise são apresentados na figura 5.9.

CLASS	1	2	3	4	5	6	7	8	9	
COUNT	2084	2552	2537	2319	2490	3046	2066	2382	2100	AVERAGE
energy	0,334	0,172	0,173	0,132	0,105	0,164	0,167	0,261	0,668	0,232
asm	0,234	0,133	0,166	0,155	0,128	0,172	0,154	0,176	0,737	0,219
B05	0,488	0,143	0,148	0,169	0,208	0,077	0,242	0,058	0,491	0,212
homogeneity	0,582	0,196	0,135	0,051	0,039	0,058	0,141	0,316	0,483	0,209
B12	0,479	0,094	0,108	0,152	0,157	0,044	0,271	0,179	0,500	0,205
ndwi	0,082	0,049	0,132	0,222	0,238	0,130	0,020	0,112	0,895	0,200
B06	0,234	0,192	0,317	0,053	0,067	0,059	0,116	0,151	0,654	0,196
B11	0,384	0,129	0,179	0,055	0,105	0,000	0,255	0,170	0,620	0,195
ihs5_s	0,336	0,214	0,127	0,184	0,227	0,078	0,244	0,118	0,294	0,195
ndvi	0,152	0,036	0,161	0,295	0,255	0,100	0,023	0,026	0,768	0,193
B07	0,194	0,192	0,323	0,080	0,035	0,065	0,095	0,146	0,663	0,191
B03	0,526	0,085	0,096	0,166	0,219	0,098	0,198	0,157	0,228	0,188
B8A	0,184	0,180	0,320	0,090	0,015	0,069	0,088	0,114	0,691	0,186
B09	0,196	0,159	0,323	0,101	0,004	0,063	0,086	0,105	0,721	0,186
B01	0,703	0,027	0,024	0,185	0,235	0,077	0,183	0,111	0,223	0,183
B08	0,178	0,183	0,315	0,084	0,025	0,078	0,086	0,118	0,648	0,183
yi_q_y	0,541	0,069	0,063	0,187	0,212	0,084	0,208	0,119	0,240	0,181
savi	0,177	0,108	0,274	0,277	0,164	0,001	0,049	0,059	0,595	0,180
evi	0,148	0,118	0,299	0,265	0,129	0,030	0,054	0,073	0,556	0,178
ihs5_i	0,548	0,055	0,047	0,192	0,207	0,081	0,205	0,103	0,234	0,175
B04	0,536	0,062	0,019	0,219	0,199	0,057	0,230	0,065	0,273	0,172
ihs5_h	0,203	0,001	0,095	0,270	0,016	0,138	0,141	0,313	0,433	0,171
yi_q_q	0,057	0,239	0,334	0,133	0,112	0,117	0,010	0,372	0,036	0,162
yi_q_i	0,549	0,032	0,007	0,222	0,189	0,053	0,217	0,039	0,251	0,160
dissimilarity	0,752	0,138	0,011	0,070	0,046	0,065	0,026	0,194	0,232	0,159
B02	0,560	0,006	0,028	0,175	0,193	0,089	0,166	0,087	0,172	0,154
contrast	0,573	0,077	0,040	0,073	0,060	0,077	0,031	0,089	0,087	0,116
correlation	0,005	0,034	0,085	0,139	0,048	0,155	0,138	0,159	0,015	0,089
AVERAGE	0,355	0,111	0,155	0,157	0,130	0,081	0,137	0,142	0,443	

Figura 5.9 - Valores da correlação para cada um dos atributos extraídos

Em cada coluna da figura está representado o valor da correlação de todos os atributos para cada uma das classes, este representa a relevância do atributo na identificação de um pixel dessa mesma classe. O valor toma o valor mínimo, zero, quando não existe qualquer relação entre o valor do atributo e a classe, e tem valor máximo, um, quando o atributo consegue representar a classe na sua totalidade, ou seja, quando é possível utilizar apenas este atributo para classificar todos pixels desta classe corretamente.

Foi calculada a média da correlação de cada uma das classes, este valor é tanto maior quanto maior a dificuldade na classificação de pixels da classe correspondente. No caso de estudo, é verificado que as classes 1 (Territórios Artificializados) e 9 (Corpos de água) são mais facilmente identificadas, como já tinha sido identificado na análise dos histogramas. Por outro lado, as restantes classes serão mais difíceis de classificar, o que também já seria de esperar, uma vez que muitas delas contêm áreas de vegetação muito idênticas.

Por fim, foi calculada a média ponderada das correlações de cada atributo, com o objetivo de identificar quais os que trazem mais informação ao *dataset* gerado. Como referido anteriormente, o atributo “correlação” não adiciona muita informação ao *dataset*. Uma possível justificação para este resultado é o desenho manual dos polígonos, uma vez que estes foram desenhados em áreas onde se encontra um conjunto de pixels da mesma Classe, ou seja, com comportamentos muito idênticos e valores dos atributos semelhantes, mesmo considerando diferentes Classes, grandes áreas de zonas de um determinado terreno têm geralmente um valor de correlação mais elevado (Hall-beyer, 2018). É possível constatar que alguns dos valores de correlação mais altos são atributos extraídos das bandas o que significa que a sua extração levou ao melhoramento do *dataset*, cumprindo assim o objetivo do projeto. Por outro lado, alguns dos atributos não acrescentam informação relevante, estes poderão ser removidos, não sendo utilizados para a construção do classificador. Esta análise de correlação permite identificar os atributos que trazem maior relevância ao *dataset* quando utilizados separadamente, não identificando relações de dependência entre ele. De modo a avaliar esta dependência de atributos foi calculada a matriz de correlação da figura 5.10.

	asm	B01	B02	B03	B04	B05	B06	B07	B08	B09	B11	B12	B8A	contrast	correlation	dissimilarity	energy	evi	homogeneity	ihs5_h	ihs5_i	ihs5_s	ndvi	ndwi	savi	viq_i	viq_q	viq_v	average
asm	1	-0,35	-0,28	-0,33	-0,36	-0,5	-0,57	-0,57	-0,55	-0,61	-0,65	-0,59	-0,58	-0,18	-0,13	-0,43	0,97	-0,38	0,79	-0,36	-0,33	-0,34	-0,55	0,65	-0,4	-0,34	0,05	-0,34	0,47
B01	-0,35	1	0,87	0,86	0,86	0,82	0,43	0,37	0,34	0,32	0,63	0,74	0,34	0,62	0,11	0,77	-0,44	-0,19	-0,63	0,35	0,87	0,59	-0,21	0,08	-0,23	0,86	0	0,87	0,53
B02	-0,28	0,87	1	0,97	0,94	0,83	0,43	0,36	0,37	0,27	0,61	0,7	0,33	0,63	0,1	0,71	-0,36	-0,21	-0,54	0,33	0,98	0,59	-0,25	0,13	-0,26	0,95	-0,03	0,98	0,54
B03	-0,33	0,86	0,97	1	0,95	0,89	0,56	0,49	0,49	0,39	0,69	0,77	0,46	0,58	0,13	0,69	-0,41	-0,1	-0,57	0,29	0,99	0,71	-0,18	0,07	-0,14	0,94	-0,2	0,99	0,57
B04	-0,36	0,86	0,94	0,95	1	0,9	0,45	0,38	0,39	0,31	0,73	0,83	0,36	0,53	0,14	0,67	-0,44	-0,24	-0,59	0,51	0,98	0,78	-0,23	0,06	-0,27	1	0,06	0,98	0,57
B05	-0,5	0,82	0,83	0,89	0,9	1	0,75	0,7	0,67	0,64	0,87	0,89	0,68	0,5	0,13	0,66	-0,55	0,13	-0,64	0,44	0,89	0,79	0,08	-0,23	0,1	0,87	-0,17	0,9	0,62
B06	-0,57	0,43	0,43	0,56	0,45	0,75	1	0,99	0,97	0,95	0,74	0,62	0,99	0,29	0,07	0,41	-0,56	0,73	-0,51	0,07	0,49	0,54	0,58	-0,61	0,7	0,41	-0,54	0,51	0,59
B07	-0,57	0,37	0,36	0,49	0,38	0,7	0,99	1	0,98	0,96	0,7	0,56	0,99	0,25	0,05	0,37	-0,55	0,78	-0,48	0,04	0,42	0,49	0,63	-0,64	0,75	0,33	-0,55	0,45	0,57
B08	-0,55	0,34	0,37	0,49	0,39	0,67	0,97	0,98	1	0,93	0,68	0,54	0,98	0,23	0,05	0,34	-0,52	0,8	-0,45	0,03	0,42	0,49	0,63	-0,64	0,77	0,34	-0,56	0,45	0,56
B09	-0,61	0,32	0,27	0,39	0,31	0,64	0,95	0,96	0,93	1	0,71	0,56	0,97	0,2	0,05	0,33	-0,58	0,79	-0,49	0,08	0,33	0,43	0,69	-0,72	0,77	0,27	-0,48	0,36	0,54
B11	-0,65	0,63	0,61	0,69	0,73	0,87	0,74	0,7	0,68	0,71	1	0,96	0,71	0,34	0,18	0,56	-0,7	0,25	-0,72	0,46	0,69	0,73	0,27	-0,42	0,25	0,7	-0,13	0,7	0,60
B12	-0,59	0,74	0,7	0,77	0,83	0,89	0,62	0,56	0,54	0,56	0,96	1	0,56	0,4	0,2	0,63	-0,66	0,04	-0,74	0,52	0,79	0,78	0,07	-0,24	0,03	0,81	-0,02	0,79	0,57
B8A	-0,58	0,34	0,33	0,46	0,36	0,68	0,99	0,99	0,98	0,97	0,71	0,56	1	0,23	0,05	0,35	-0,55	0,8	-0,47	0,06	0,39	0,47	0,66	-0,68	0,78	0,31	-0,53	0,41	0,56
contrast	-0,18	0,62	0,63	0,58	0,53	0,5	0,29	0,25	0,23	0,2	0,34	0,4	0,23	1	0	0,89	-0,26	-0,08	-0,46	0,1	0,58	0,22	-0,11	0,07	-0,12	0,54	-0,02	0,57	0,36
correlation	-0,13	0,11	0,1	0,13	0,14	0,13	0,07	0,05	0,05	0,05	0,18	0,2	0,05	0	1	0,08	-0,2	-0,05	-0,17	0,06	0,12	0,15	-0,1	0,05	-0,05	0,13	-0,04	0,13	0,13
dissimilarity	-0,43	0,77	0,71	0,69	0,67	0,66	0,41	0,37	0,34	0,33	0,56	0,63	0,35	0,89	0,08	1	-0,54	-0,06	-0,78	0,24	0,7	0,4	-0,06	-0,02	-0,09	0,68	0	0,7	0,47
energy	0,97	-0,44	-0,36	-0,41	-0,44	-0,55	-0,56	-0,55	-0,52	-0,58	-0,7	-0,66	-0,55	-0,26	-0,2	-0,54	1	-0,3	0,9	-0,36	-0,41	-0,39	-0,44	0,55	-0,32	-0,42	0,04	-0,42	0,49
evi	-0,38	-0,19	-0,21	-0,1	-0,24	0,13	0,73	0,78	0,8	0,79	0,25	0,04	0,8	-0,08	-0,05	-0,06	-0,3	1	-0,11	-0,28	-0,19	-0,03	0,86	-0,76	0,99	-0,28	-0,59	-0,16	0,40
homogeneity	0,79	-0,63	-0,54	-0,57	-0,59	-0,64	-0,51	-0,48	-0,45	-0,49	-0,72	-0,74	-0,47	-0,46	-0,17	-0,78	0,9	-0,11	1	-0,35	-0,58	-0,47	-0,2	0,3	-0,11	-0,58	0,01	-0,58	0,51
ihs5_h	-0,36	0,35	0,33	0,29	0,51	0,44	0,07	0,04	0,03	0,08	0,46	0,52	0,06	0,1	0,06	0,24	-0,36	-0,28	-0,35	1	0,39	0,4	-0,02	-0,22	-0,24	0,52	0,58	0,37	0,31
ihs5_i	-0,33	0,87	0,98	0,99	0,98	0,89	0,49	0,42	0,42	0,33	0,69	0,79	0,39	0,58	0,12	0,7	-0,41	-0,19	-0,58	0,39	1	0,72	-0,22	0,08	-0,23	0,98	-0,05	1	0,57
ihs5_s	-0,34	0,59	0,59	0,71	0,78	0,79	0,54	0,49	0,49	0,43	0,73	0,78	0,47	0,22	0,15	0,4	-0,39	-0,03	-0,47	0,4	0,72	1	-0,11	-0,05	-0,05	0,73	-0,16	0,73	0,48
ndvi	-0,55	-0,21	-0,25	-0,18	-0,23	0,08	0,58	0,63	0,63	0,69	0,27	0,07	0,66	-0,11	-0,1	-0,06	-0,44	0,86	-0,2	-0,02	-0,22	-0,11	1	-0,95	0,9	-0,26	-0,25	-0,21	0,38
ndwi	0,65	0,08	0,13	0,07	0,06	-0,23	-0,61	-0,64	-0,64	-0,72	-0,42	-0,24	-0,68	0,07	0,05	-0,02	0,55	-0,76	0,3	-0,22	0,08	-0,05	-0,95	1	-0,81	0,08	0,11	0,07	0,37
savi	-0,4	-0,23	-0,26	-0,14	-0,27	0,1	0,7	0,75	0,77	0,77	0,25	0,03	0,78	-0,12	-0,05	-0,09	-0,32	0,99	-0,11	-0,24	-0,23	-0,05	0,9	-0,81	1	-0,31	-0,53	-0,2	0,41
viq_i	-0,34	0,86	0,95	0,94	1	0,87	0,41	0,33	0,34	0,27	0,7	0,81	0,31	0,54	0,13	0,68	-0,42	-0,28	-0,58	0,52	0,98	0,73	-0,26	0,08	-0,31	1	0,13	0,97	0,56
viq_q	0,05	0	-0,03	-0,2	0,06	-0,17	-0,54	-0,55	-0,56	-0,48	-0,13	-0,02	-0,53	-0,02	-0,04	0	0,04	-0,59	0,01	0,58	-0,05	-0,16	-0,25	0,11	-0,53	0,13	1	-0,09	0,25
viq_v	-0,34	0,87	0,98	0,99	0,98	0,9	0,51	0,45	0,45	0,36	0,7	0,79	0,41	0,57	0,13	0,7	-0,42	-0,16	-0,58	0,37	1	0,73	-0,21	0,07	-0,2	0,97	-0,09	1	0,57

Figura 5.10 - Valores de correlação entre os atributos extraídos

A matriz de correlação permite identificar valores dependências lineares entre pares de atributos, que variam entre -1 e 1, respetivamente no caso de existir uma relação linear negativa ou positiva. Pares de atributos com correlação nula são linearmente independentes, isto significa que a utilização de ambos os atributos para geração de um classificador é uma boa escolha, uma vez que estes não apresentam informação redundante.

Podemos verificar que os grupos de bandas B02, B03, B04 e B06, B07, B08 apresentam uma correlação bastante alta, isto poderá acontecer devido à relativa pouca diferença de comprimento de onda entre elas. Existe também uma grande dependência entre os vários índices de vegetação, e uma dependência linear negativa entre estes e o NDWI que tem o objetivo de identificar zonas com presença de água.

Por último, está presente na última coluna da tabela uma média dos módulos da correlação de cada atributo. Valores mais baixos desta média representam atributos que são mais independentes, sendo a correlação o atributo com maior nível de independência, este fato também foi identificado em (Hall-beyer, 2018). É importante notar que um baixo valor médio desta correlação não leva a que este atributo seja um bom atributo a ser utilizado na geração do classificador, uma vez que apenas representa a independência com os restantes atributos, e não a sua relação com cada uma das Classes. A escolha dos atributos deve, assim, ser feita tendo em conta ambas as figuras 5.9 e 5.10. Considerando primeiro a qualidade do atributo em relação à distribuição dos valores dos pixels para cada Classe e depois a independência deste atributo em relação aos restantes de modo a diminuir a informação redundante para o *dataset*, permitindo a geração de modelos de classificação mais simples.

É ainda importante referir que a ferramenta desenvolvida serve de auxílio para a construção do *dataset*, os índices foram escolhidos como prova de conceito, e é possível a adição de novos índices por parte do utilizador de acordo com as suas especificações. A escolha destes índices, a imagem em estudo do *Sentinel*, bem como o desenho manual dos polígonos são fatores que fazem variar significativamente a qualidade do *dataset*.

6 Conclusões e Trabalho Futuro

6.1 Conclusões

O trabalho realizado permitiu o desenvolvimento de uma aplicação que possibilita a extração de atributos para a criação de *datasets* para classificação da ocupação de solo através de imagens aéreas do nível 2A do Satélite *Sentinel-2*.

Após a geração de um exemplo de *dataset* foi concluído que alguns dos atributos extraídos da imagem como a energia e o índice NDWI adicionaram informação relevante ao mesmo. Mesmo assim, alguns dos atributos obtiveram resultados menos positivos. É, assim, importante salientar que a ferramenta desenvolvida serve apenas para a extração automática dos atributos da imagem da superfície da terra. A qualidade do *dataset* criado depende diretamente de fatores como o desenho dos polígonos por parte do utilizador bem como da qualidade da imagem do *Sentinel-2* em estudo.

Outro aspeto importante a ter em conta na utilização dos *datasets* criados é que o classificador tendo por base uma imagem do *Sentinel-2*, não garante bons resultados na classificação de outra imagem. Isto ocorre devido a vários fatores, em primeiro lugar a sazonalidade, uma zona de vegetação, por exemplo, tem grande variação ao longo do período sazonal de um ano; em segundo lugar a hora de recolha dos dados do satélite afeta os seus valores, devido à posição do sol; e, em último lugar, os fatores atmosféricos podem também alterar os valores dos atributos de imagem para imagem.

Uma forma de combater estes problemas é a recolha de atributos de várias imagens de períodos do ano distintos, bem como adição de atributos temporais, como a adição do mês de recolha da imagem, tendo assim dados que representem cada uma das Classes em situações distintas.

Em suma, os objetivos traçados no começo do desenvolvimento da dissertação foram de um modo geral cumpridos, sendo que a aplicação criada permite a criação automática de conjuntos de treino para posterior geração de classificadores e consequente aumento da rapidez de produção de mapas de ocupação do território. Porém existem ainda alguns pontos que ainda poderão ser melhorados.

6.2 Trabalho Futuro

Após conclusão deste trabalho pode-se ainda identificar alguns possíveis pontos a melhorar no futuro. A análise de várias imagens aéreas de diferentes períodos do ano, de modo a criar um modelo de classificação mais robusto e generalizado, combatendo as perturbações atmosféricas e a sazonalidade. A adição de atributos temporais, indicando, por exemplo, a data de recolha da imagem, de modo a que o classificador tenha em conta qual o período do ano a ser classificado.

A adição de outros tipos de atributos, como a inclinação do solo, é também um ponto que pode ser melhorado, apesar de aumentar o tempo de produção do *dataset*, novos atributos podem sempre trazer informação relevante para a criação do classificador.

No que diz respeito à aplicação desenvolvida, podem ser adicionadas algumas funcionalidades que tornam a sua utilização mais conveniente, entre elas a adição de um algoritmo de segmentação que permite a criação automática dos polígonos, a visualização da distribuição dos valores dos atributos dos polígonos desenhados sob a forma de histograma ou a possibilidade de editar os polígonos da COS, facilitando a seleção e/ou desenho de polígonos que ainda se encontrem atualizados na sua maioria.

A extração dos atributos relativos à textura da imagem é o processo mais demorado do processamento para a geração do *dataset*, esta tarefa é facilmente paralelizada podendo a sua implementação em placa gráfica ser uma grande mais valia para a re-

dução do tempo de produção do mesmo. O aumento da velocidade deste processamento pode levar à escolha de um número mais elevado de níveis de cinzento aquando a extração destes atributos.

Referências

- Albregtsen, F. (2008). Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices, 1–14.
- Ayhan, E., & Kansu, O. (2012). Analysis of image classification methods for remote sensing. *Experimental Techniques*, 36(1), 18–25. <https://doi.org/10.1111/j.1747-1567.2011.00719.x>
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., & Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3–4), 239–258. <https://doi.org/10.1016/j.isprsjprs.2003.10.002>
- Bittencourt, H. R., & Clarke, R. T. (n.d.). *Feature Selection By Using Classification and Regression Trees (Cart)*. Retrieved from <http://www.cartesianos.com/geodoc/isprs2004/comm7/papers/13.pdf>
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., ... Tiede, D. (2014). Geographic Object-Based Image Analysis - Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>
- Brecht. (2018). Remote Sensing Indices. Retrieved from <https://medium.com/regen-network/remote-sensing-indices-389153e3d947>
- Caetano, M., Marcelino, F., Igreja, C., & Girão, I. (2018). A ocupação e uso do solo em 2015 e dinâmicas territoriais 1995-2007-2010-2015 em Portugal Continental. Retrieved from <http://mapas.dgterritorio.pt/atom-dgt/pdf-cous/COS2015/COS2015-e-dinamicas-junho-2018.pdf>
- Castelluccio, M., Poggi, G., Sansone, C., Verdoliva, L., & Aug, C. V. (2015). Land Use Classification in Remote Sensing Images by Convolutional Neural Networks, 1–11.
- Epiphany, J. C. N., & Huete, A. R. (1995). Dependence of NDVI and SAVI on sun/sensor geometry and its effect on fAPAR relationships in Alfalfa. *Remote Sensing of Environment*, 51(3), 351–360. [https://doi.org/10.1016/0034-4257\(94\)00110-9](https://doi.org/10.1016/0034-4257(94)00110-9)
- Foody, G. M. (1992). *Derrivation and applications of probablistic measures of class membership from maximum-likelihood classification*. *Photogrammetric Engineering & Remote Sensing* (Vol. 58). <https://doi.org/10.3851/IMP1936>

- G. Meinel, M. N., & Leibniz. (2004). A comparison of segmentation programs for high resolution remote sensing data, *7*, 17–22.
- Gao, B. C. (1996). NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, *58*(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- GisGeography. (2018). Retrieved from <https://gisgeography.com/spectral-signature/>
- Hall-beyer, M. (2018). GLCM Texture, (February).
- Hall, M. A. (1999). *Correlation-based Feature Selection for Machine Learning*. Retrieved from <https://www.lri.fr/~pierres/donn%E9es/save/these/articles/lpr-queue/hall99correlationbased.pdf>
- Haralick, R. M. (1979). Statistical and Structural Approaches to Texture, *67*(5).
- Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. <https://doi.org/10.3390/rs8030166>
- Jordi Inglada, Marcela Arias, Benjamin Tardy, Olivier Hagolle, S. V., & David Morin, Gérard Dedieu, Guadalupe Sepulcre, Sophie Bontemps, Pierre Defourny, and B. K. (2015). Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery, *4*, 12356–12379. <https://doi.org/10.3390/rs70912356>
- Joshua Stevens, Jennifer M. Smith, and R. A. B. (2018). Mapping our Changing World. Retrieved February 6, 2019, from <https://www.e-education.psu.edu/geog160/node/1405>
- Kalyankar, N. V, & Nanded, Y. M. (2011). The IHS Transformations Based Image Fusion, (July).
- Langley, P. (1994). *Selection of Relevant Features in Machine Learning. AAAI Technical Report*. Retrieved from www.aaai.org
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Mário Caetano, C. I. e F. M. (2018). COS2007 - Carta de uso e ocupação do solo de Portugal continental. Retrieved from http://www.dgterritorio.pt/cartografia_e_geodesia/cartografia/cartografia_tematica/carta_de_ocupacao_do_solo__cos_/cos__2007/ (último acesso em Fevereiro de 2015)
- Mark A. Hall, L. A. S. (1998). *Practical Feature Subset Selection for Machine Learning* (Vol. Volume 20). Retrieved from

<https://researchcommons.waikato.ac.nz/handle/10289/1512>


- Mora, A., Santos, T. M. A., Lukasik, S., Silva, J. M. N., Falcão, A. J., Fonseca, J. M., & Ribeiro, R. A. (2017). Land cover classification from multispectral data using computational intelligence tools: A comparative study. *Information (Switzerland)*, 8(4). <https://doi.org/10.3390/info8040147>
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217–222. <https://doi.org/10.1080/01431160412331269698>
- Penatti, O. A. B., Nogueira, K., & Dos Santos, J. A. (2015). Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2015–Octob*, 44–51. <https://doi.org/10.1109/CVPRW.2015.7301382>
- Romero, A., Gatta, C., & Camps-Valls, G. (2016). Unsupervised deep feature extraction for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3), 1349–1362. <https://doi.org/10.1109/TGRS.2015.2478379>
- Santos, T. M. A., Mora, A., Ribeiro, R. A., & Silva, J. M. N. (2016). Fuzzy-fusion approach for land cover classification. *INES 2016 - 20th Jubilee IEEE International Conference on Intelligent Engineering Systems, Proceedings*, 177–182. <https://doi.org/10.1109/INES.2016.7555116>
- Schiewe, J. (2002). *Segmentation of high-resolution remotely sensed data-concepts, applications and problems. Evaluation*. Retrieved from http://test.ecognition.com/sites/default/files/383_358.pdf
- Singh, A. (2010). Review Article Digital change detection techniques using remotely-sensed data, 1161. <https://doi.org/10.1080/01431168908903939>
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017, 1–17. <https://doi.org/10.1155/2017/1353691>
- Ye, S., Pontius, R. G., & Rakshit, R. (2018). A review of accuracy assessment for object-based image analysis: From per-pixel to per-polygon approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 141, 137–147. <https://doi.org/10.1016/j.isprsjprs.2018.04.002>
- Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., & Schirokauer, D. (2006). Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. *Photogrammetric Engineering & Remote Sensing*, 72(7),







799–811. <https://doi.org/10.14358/PERS.72.7.799>







- Zhang, G., Jia, X., & Kwok, N. M. (2011). Spectral-spatial based super pixel remote sensing image classification. *Proceedings - 4th International Congress on Image and Signal Processing, CISP 2011, 3*, 1680–1684. <https://doi.org/10.1109/CISP.2011.6100425>
- Zhang, G., Jia, X., & Kwok, N. M. (2012). Super pixel based remote sensing image classification with histogram descriptors on spectral and spatial data. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4335–4338. <https://doi.org/10.1109/IGARSS.2012.6351708>
- Zhang, Y., & Hong, G. (2005). An IHS and wavelet integrated approach to improve pan-sharpening visual quality of natural colour IKONOS and QuickBird images. *Information Fusion, 6*(3), 225–234. <https://doi.org/10.1016/j.inffus.2004.06.009>
- Zheng, H., Du, P., & Chen, J. (2017). Performance Evaluation of Downscaling Sentinel-2 Imagery for Land Use and Land Cover Classification by Spectral-Spatial Features. <https://doi.org/10.3390/rs9121274>




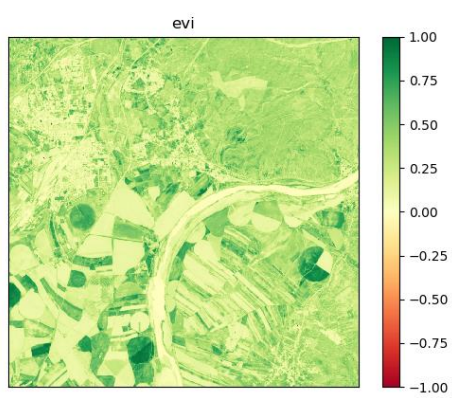


Anexos






A. Imagens dos atributos extraídos












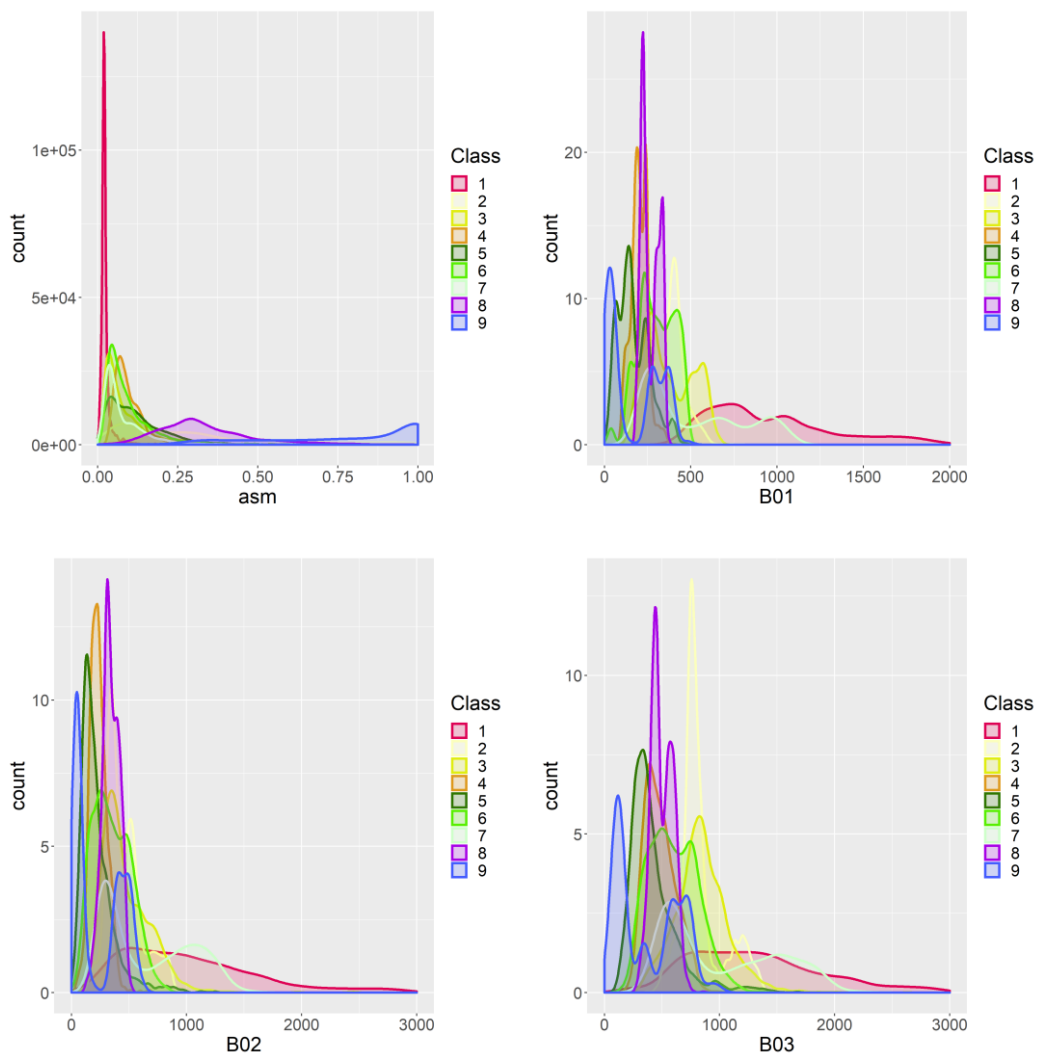




















Figura 0.1 - Imagens da zona de corte dos atributos extraídos







B. Histogramas da distribuição dos valores dos atributos














Figura 0.2 - Histogramas da distribuição dos valores dos atributos para cada uma das Classes. (1. Terrenos Artificializados; 2. Agricultura; 3. Pastagens; 4. Sistemas Agro-Florestais; 5. Floresta; 6. Matos; 7. Espaços descobertos ou com vegetação esparsa; 8. Zonas húmidas; 9. Corpos de água)

C. Manual da aplicação

Instalação

- Instalar QGIS-OSGeo4W 2.18 (Las Palmas) (<https://qgis.org/downloads/>);
- Abrir o ficheiro 'launch.bat' e verificar se as directorias estão corretas;
- Abrir o ficheiro 'app.py' e verificar se a directoria 'qgis_ltr_dir' está correta;
- Abrir a consola OSGeo4W Shell;
- Navegar para a pasta da aplicação 'dataset_generator' através de comandos 'cd';
- > setup.py

Criar o workspace

O *workspace* é a pasta do projeto onde são guardados os ficheiros para o correto funcionamento da aplicação, este deve ser criado antes de abrir da sua abertura.

- Abrir a consola OSGeo4W Shell;
- Navegar para a pasta da aplicação 'dataset_generator' através de comandos 'cd';
- > launch.bat (este *script* deve ser corrido sempre que o OSGeo4W é aberto);
- > python create_workspace.py;
- Dentro da janela aberta, clique do lado direito, e criar nova pasta (esta vai ser a pasta do seu *workspace*);
- Selecionar essa pasta (selecionar mesmo a pasta, não a abrir);
- Na janela 'Select Raster Layer' procurar a imagem TCI da imagem do Sentinel a analisar, esta imagem pode ser encontrada dentro da pasta: 'GRANULE/L2A.../IMG_DATA/10m/...TCI_10m.jp2';
- Selecionar quais os atributos a extrair (TCI, false_color, bandas e cos são imagens que também serão extraídas);
- A extração dos atributos pode demorar algum tempo (~12 horas quando o atributo *haralick features* é selecionado);

Abrir a aplicação

Depois de criado o *workspace* este pode ser aberto através da aplicação, é na aplicação que o utilizador deve desenhar os polígonos para geração dos ficheiros finais do *dataset*.

- Abrir a consola OSGeo4W Shell;
- Navegar para a pasta da aplicação 'dataset_generator' através de comandos 'cd';
- > launch.bat (este script deve ser corrido sempre que o OSGeo4W é aberto);
- >python app.py;
- Clicar 'load' e seleccionar a pasta do workspace criada anteriormente;
- Desenhar os polígonos no Canvas da aplicação (botão esquerdo para desenhos, botão direito para finalizar);
- Clicar botão 'generate_dateset' para gerar o dataset final, este estará preparado para utilização na pasta 'dataset' dentro da diretoria do workspace;

As funcionalidades da aplicação bem como uma descrição detalhada do seu funcionamento encontra-se no capítulo 4.9 desta dissertação.